



**Sveučilište u Splitu**  
**EKONOMSKI FAKULTET**

**DIPLOMSKI RAD**  
**ANALITIKA WEB STRANICA HRVATSKIH**  
**HOTELA**

**Mentor:**

**Dr.sc. Nikša Alfirević**

**Student:**

**Petar Čerina**

**Split, kolovoz, 2017.**

## **Sažetak**

U radu su prikazana teorijska i empirijska istraživanja na području web analitike hotelskih poduzeća.

Prati se konkretan primjer izrade web stranice hotelskog poduzeća od utvrđivanja problema s postojećom web stranicom pomoću alata za web analitiku, preko planiranja, istraživanja, implementacije te praćenja uspješnosti rezultata nove web stranice.

Na osnovu utvrđenog problema pomoću web analitike, pristupa se procesu rudarenja podataka s konkurentskih web stranica kako bi se dobio prijedlog modela nove web stranice. Nakon implementacije nove web stranice provodi se usporedba dobivenih rezultata i procjena uspješnosti nove web stranice.

## **Abstract**

This thesis is representing theoretical and empirical researches in domain of hotel website analytics.

Object of research is design and implementation of new hotel website from problem locating with current website, followed by planning , researching, implementing and controlling the newly implemented site.

Based on located problem, data mining of competitors websites is taken. Results of data mining gave a model that will be base for designing of new website. After the implementation of new website, statistics were tracked and the estimates of results has been made.

## Sadržaj

1. UVOD .....	4
1.1. Problem istraživanja.....	4
1.2. Predmet istraživanja.....	5
1.3. Istraživačke hipoteze.....	7
1.4. Ciljevi istraživanja .....	8
1.5. Metode rada .....	9
1.6. Doprinos istraživanja .....	10
1.7. Struktura rada.....	10
2. Poslovna inteligencija u hrvatskim hotelima .....	11
3. Analiza web sadržaja hotelskih stranica .....	14
3.1. Web mjesto .....	16
3.2. Utjecaj sadržaja web stranice hotela na donošenje odluke turista .....	19
3.2.1. Osnovni elementi web stranice hotela .....	22
3.3. Web analitika .....	23
3.3.1. Web analitika i optimizacija konverzija .....	25
3.3.2. Praćenje i prikupljanje podataka .....	28
3.3.3. Alati za web analitiku .....	34
3.3.4. Google Analytics .....	37
3.3.5. Izvještaji u Google Analyticsu.....	39
4. Empirijsko istraživanje .....	43
4.1. Analiza rezultata postojeće web stranice poduzeća Colosseum .....	43
4.1.1. O poduzeću Colosseum.....	43
4.1.2. Vizija i misija poduzeća.....	44
4.1.3. Strategija razvoja poduzeća .....	45
4.1.4. Poslovni ciljevi poduzeća .....	46
4.2. Trenutno stanje i rezultati web stranice .....	46
4.3. Pristup izradi nove stranice.....	52
4.4. Istraživanje .....	53
5. Izvještaj rezultata istraživanja i prijedlog izrade web stranice .....	62
5.1. Rezultati nakon implementacije.....	67
5.2. Testiranje i potvrda hipoteza.....	69
6. Zaključak.....	70
LITERATURA .....	73
TABLICA GRAFOVA .....	75
TABLICA SLIKA .....	75
TABLICA TABLICA .....	75

# 1. UVOD

## 1.1. Problem istraživanja

U modernom, elektronskom dobu marketinška komunikacija na webu te web poslovanje postaju sve važnije, kako za poduzeća tako i za klijente. Internet pruža prednosti kao što su dostupnost, praktičnost, interaktivna komunikacija i vremenska neograničenost. Dakle, poduzeća imaju bolji uvid u želje svojih klijenata, smanjuju troškove poslovanja, olakšana im je komunikacija s klijentima, izravno su povezani s klijentima na dnevnoj bazi, olakšan im je način dobivanja informacija o željama i preferencijama klijenata kao i profiliranje klijenata prema podacima koje ostavljaju na webu ili pak prema njihovom ponašanju na webu. S druge strane, klijentima je dostupno mnogo više informacija o proizvodima i uslugama koje ih interesiraju. Ušteda vremena i novca je jedna od najvećih prednosti, klijenti više ne moraju obilaziti fizičke lokacije da bi saznali informacije koje ih zanimaju već su im one dostupne na webu. Dakle, klijenti su mnogo informiraniji o proizvodima i uslugama te samostalno donose odluke o kupovini, stoga se lakše i povezuju s određenim brandovima te tako često postaju lojalni kupci. Upravo su lojalni kupci, odnosno klijenti jedan od glavnih ciljeva skoro svih poduzeća. Lojalni klijenti tako mogu uvelike doprinijeti povećanju popularnosti branda dijeleći svoja iskustva o korištenju proizvoda i usluga na drugim web mjestima i socijalnim mrežama.

Poduzeća su tako velike napore usmjerila na web prisutnost, kako na prisutnost na društvenim mrežama tako i izradom sve atraktivnijih i funkcionalnijih web stranica. Dugo godina su web stranice služile samo kao tzv. „oglasne ploče“ na kojima su poduzeća uglavnom objavljivala osnovne informacije vezane uz njihovu djelatnost, a pritom je i sam grafički dizajn stranica bio u drugom planu. U novije vrijeme su se stvari uvelike promijenile, poduzeća su shvatila koliki je potencijal weba, da je moguće dosegnuti širok raspon potrošača sa svojom porukom, odnosno proizvodom ili uslugom, te su se okrenuli velikim ulaganjima u web prisutnost. Web stranice su postale izvor zarade, web shopovi postaju jedni od najprofitabilnijih poduzeća na svijetu (eBay, Alibaba, Amazon...) te preuzimaju veliki udio prometa trgovinama s fizičkim

lokacijama. Osim web trgovina, web stranice se uvelike koriste od strane pružatelja usluga koji uglavnom nude mogućnosti rezervacije svojih usluga. Jedan takav primjer su rezervacije hotelskog smještaja, preko web stranice, koje su postale jedan od imperativa u suvremenoj hotelskoj praksi.

Problem istraživanja rada je web stranica hotela Colosseum d.d.<sup>1</sup> sa sjedištem na Hvaru. Hotelsko poduzeće Colosseum d.d. ima web stranicu koja uglavnom služi u informativne svrhe potencijalnim gostima. Jedan od glavnih nedostataka je nepostojanje sustava za online rezervacije te uprava smatra da je implementacija takvog sustava jedan od primarnih zadataka. Također, stranica nema responzivan dizajn te je loše optimizirana što utječe na nisku poziciju na tražilicama. Navigacija na stranici je izrazito loša te se korisnik može vrlo lako pogubiti u pretrazi, linkovi su uglavnom neispravni, a animacije na stranici uopće ne postoje.

Uprava hotela se odlučila na izradu novih web stranica, ali prije toga žele provesti analizu web stranica ostalih hotela u Hrvatskoj kako bi saznali koje su najbolje prakse koje bi iskoristili za kreiranje što bolje vlastite web stranice.

## **1.2. Predmet istraživanja**

Turizam je jedna od najbrže rastućih gospodarskih grana na svijetu. Sukladno rastu, koristi se sve više tehnoloških inovacija te se poslovanje turističkih objekata nastoji što više modernizirati. Ovaj rad se koncentrira na hotelsku industriju koja je najsnažnija unutar sektora turizma. U 2016. godini, na svjetskoj razini, prihodi hotelske industrije su iznosili 550 mlrd. američkih dolara<sup>2</sup>. U posljednjih deset godina prihodi hotelske industrije su porasli za 100 mlrd. dolara. Velik doprinos tim brojkama daje povećanje prisutnosti hotela na webu. Hoteli postaju jedni od najvećih ulagača u promociju na društvenim mrežama i internet tražilicama, a isto tako ulažu velika sredstva u izradu što atraktivnijih i funkcionalnijih web stranica.

---

<sup>1</sup> Zbog zahtjeva o tajnosti podataka od strane poduzeća koje je objekt istraživanja, u radu se koristi fiktivno ime Colosseum d.d.

<sup>2</sup> <https://www.statista.com/topics/1102/hotels/>, (26.08.2016.)

Web stranice turističkih objekata postaju jedno od centralnih mjesta promocije na kojemu posjetitelji saznaju sve što ih zanima o objektu. Osim informacija, posjetitelji na svakoj kvalitetnijoj hotelskoj web stranici mogu izvršiti rezervaciju smještaja. U 2016. godini rezervacije putovanja i smještaja putem onlinea iznose 186,861.4 milijuna USD, a od toga čak 106,929.5 milijuna USD se odnosi na hotelski smještaj.<sup>3</sup> Prema projekcijama Statista, portala za statistiku, u slijedeće četiri godine ovi prihodi će se povećati za malo manje od 25%.

Prije pristupanja izradi web stranice, od velike je važnosti da turistički djelatnici poznaju ponašanje turista kako bi sama web stranica mogla što bolje odgovoriti na sve želje i zahtjeve turista. Također, važno je i da turistički djelatnici budu upoznati i s načinom na koji potencijalni posjetitelji traže informacije, koliko su im informacije iz pojedinih izvora važne i na temelju kojih čimbenika donose odluku o putovanju, izboru turističke destinacije i smještajnog objekta. Prema Moutinhu (2000.) model ponašanja turista sastoji od tri dijela: 1) proces prije donošenja odluke i donošenje odluke, 2) procjena nakon kupnje i 3) buduće odlučivanje. Prva faza je ujedno i najvažnija jer ostale faze ovise o njoj, u ovoj fazi turist je izložen velikom broju utjecaja i donosi odluku o kupnji. Turist istražuje razne izvore informacija kako bi što lakše donio odluku. Jedan od najvažnijih izvora informacija pritom je internet. Kako bi online pretraživanje informacija bilo uspješno moraju biti ispunjena tri uvjeta: jednostavnost pristupa informacijama, jednostavnost upotrebe i pouzdanost<sup>4</sup>. Prema tome, web stranice bi trebale biti intuitivne, interaktivne i kompatibilne s drugim mehanizmima pretraživanja kako bi turist što lakše donio svoju odluku. Prema prethodnim istraživanjima o važnosti izgleda i sadržaja web stranice ispostavilo se da su prilikom odabira destinacije najvažnije informacije o ponudi destinacije, opis destinacije i mogućnosti rezervacija, dok funkcionalnost web stranica u ranoj fazi procesa planiranja putovanja nije od velike važnost. Prema istraživanju koje su provele autorice Kraljić i Lončarić (2015.) turistima su najvažnije informacije o cijenama, načinu plaćanja te slike hotela. Ove kategorije turisti smatraju najvažnijima, osim njih još im je važno da su dostupni kontakt podaci, informacije o cijenama za online rezervaciju, opis slike i smještaja, karta položaja hotela u gradu te slike hotelskog okružja.

---

<sup>3</sup> <https://www.statista.com/outlook/262/100/online-travel-booking/worldwide#> (26.08.2016.)

<sup>4</sup> Kozak, M. i Decrop, A. (2009.): Handbook of Tourist Behavior: theory & practice, Taylor & Francis, New York, str. 213

### 1.3. Istraživačke hipoteze

Da bi ostvarili željene ciljeve istraživanja, postaviti će se hipoteze na temelju prethodno opisanog problema i predmeta istraživanja. Glavna hipoteza se odnosi na doprinos analitike web stranica konkurenata pri izradi nove web stranice hotela. Žele se pronaći najbolje prakse pri izradi stranica da bi se kreirala stranica koja će privući što veći broj posjetitelja koji će potencijalno htjeti izvršiti rezervaciju smještaja online.

**Glavna hipoteza  $H_0$ :** Analitika web stranica hotela će utjecati na povećanje prometa na web stranicama hotela Colosseum

Da bi se glavna hipoteza dokazala, izvještaji iz baze podataka bi trebali biti temelj i smjernice pri izgradnji nove, moderne, atraktivne i intuitivne web stranice, koje ima integriran sustav online rezervacije, a koja u isto vrijeme ima najbolju i najraznovrsniju ponudu smještaja prilagođenu za sve grupe posjetitelja. Na temelju istraživanja će biti dizajnirana i implementirana nova web stranica koja će privući veći broj posjetitelja.

Osim glavne hipoteze, postavljaju se i pomoćne hipoteze koje određuju smjer istraživanja. Prva hipoteza se odnosi na povezanost između kategorizacije hotela i kvalitete web stranice hotela.

**Hipoteza 2  $H_0$ :** Web analitikom se mogu utvrditi problemi na web stranicama

Treća hipoteza se odnosi na mogućnost da s pomoću statistika o prometu na stranicama utvrdimo nedostatke koje stranica ima. Hipoteza je istinita ukoliko metrike pokažu da stranica ima određen problem ili nedostatak.

**Hipoteza 3  $H_0$ :** Google Analytics je najčešće korišten alat za analitiku prometa s web stranicama hotela u Hrvatskoj.

Hipoteza je istinita ako se pokaže da više od 50% web stranica iz istraživanja ima instaliran Google Analytics na svojim web stranicama.

Istinitost svih hipoteza će se utvrditi na osnovu izvještaja iz baze podataka. Baza podataka će se formirati pomoću podataka dobivenih iz analitike web stranica.

#### **1.4. Ciljevi istraživanja**

Znanstveni cilj rada je proširenje spoznaje o web stranicama kao izvorima prometa i prihoda za hotele u Republici Hrvatskoj.

Cilj ovog rada je utvrditi koje sve elemente sadržavaju web stranice dostupnih hotela u Republici Hrvatskoj, zatim koji od tih elemenata čine najbolje prakse za izradu web stranice hotela. Posebno će se raščlaniti tehnički elementi kao i elementi ponude hotelskog sadržaja te će se utvrditi koji od tih elemenata su najzastupljeniji na web stranicama promatranih hotela. Cilj rada je i dokazati da hoteli koji ulažu u razvoj web stranica ostvaruju veće prihode od hotela koji ne pridaju velik značaj web stranicama već se služe tradicionalnim načinima privlačenja gostiju i rezerviranja smještaja. Ipak, kao glavni cilj rada postavlja se pronalazak najboljeg mogućeg modela web stranice za hotelsko poslovanje koji će biti predložen upravi hotela Colosseum kao najbolja praksa za izradu nove web stranice.

Osim toga, cilj rada je i formiranje modela poslovne inteligencije pomoću kojeg će menadžment na osnovi podataka iz istraživanja moći planirati svoje daljnje akcije vezane za unaprjeđenje web marketinga hotela. Dakle, ovaj rad predstavlja utjecaj korištenja poslovne inteligencije kao sredstva za unaprjeđenje postojećih poslovnih procesa. Baza podataka koja će se formirati prikupljanjem podataka bit će korištena kao potpora odlučivanju pri kreiranju nove web stranice hotela, a osim primarne svrhe, baza podataka će se moći koristiti i za usporedbu s konkurentima, odnosno benchmarking te kao potpora pri odlučivanju u budućim poslovnim procesima.



## 1.5. Metode rada

Uzevši u obzir problem, predmet, hipoteze i ciljeve istraživanja te različite zahtjeve koje postavljaju teorijski i empirijski dio rada, određuju se metode istraživanja koje će se koristiti prilikom izrade diplomskog rada. Analitika web stranica zahtijeva prikupljanje i analiziranje relevantne znanstvene i stručne literature.

Teorijski dio rada će se temeljiti na spoznajama proizašlim iz analize domaće i međunarodne znanstvene literature koja će uključivati knjige, znanstvene članke, članke koji se bave problematikom koju ovaj rad istražuje te stručnim i znanstvenim časopisima.

Znanstvene metode koje će se koristiti pri izradi rada<sup>5</sup>:

- **Metoda analize** – znanstveno istraživanje raščlanjivanjem složenih pojmova, sudova i zaključaka na njihove jednostavnije sastavne dijelove i elemente
- **Deduktivna i induktivna metoda** – metode za donošenje posebnih ili pojedinačnih zaključaka
- **Metoda dokazivanja** – utvrđivanje točnosti neke spoznaje
- **Metoda klasifikacije** – sistemska i potpuna podjela općeg pojma na posebne
- **Metoda deskripcije** – postupak jednostavnog opisivanja

Da bi uspjeli potvrditi ili opovrgnuti postavljene hipoteze koristit će se statistička metoda. Ova metoda će se koristiti na način da će se iz formirane baze podataka pomoću alata za izvještavanje kreirati izvještaj koji će sadržavati statističke podatke pomoću kojih će se donositi zaključci i prijedlozi. Baza podataka će biti kreirana ručnim pretraživanjem web stranica svih hotela u Hrvatskoj koji imaju web stranicu, a jedini kriterij je da hotel ima minimalno tri zvjezdice.

---

<sup>5</sup> [http://www.unizd.hr/portals/4/nastavni\\_mat/1\\_godina/metodologija/metode\\_znanstvenih\\_istrazivanja.pdf](http://www.unizd.hr/portals/4/nastavni_mat/1_godina/metodologija/metode_znanstvenih_istrazivanja.pdf) (10.09.2016.)

## **1.6. Doprinos istraživanja**

Ovaj rad će predstavljati doprinos znanstvenoj literaturi i empirijskim istraživanjima iz područja korištenja poslovne inteligencije u poslovanju turističkih objekata, u ovom slučaju hotela. Zaključci doneseni na temelju istraživanja će se odnositi na web stranice svih dostupnih hotela u Republici Hrvatskoj koji imaju tri ili više zvjezdica.

Doprinos ovog rada će se temeljiti na dokazivanju postavljenih hipoteza. U slučaju potvrđivanja istinitosti postavljenih hipoteza, rad će doprinijeti ponajprije kreiranju nove, uspješne web stranice za poduzeće Colosseum d.d., ali isto tako rad može poslužiti i svim ostalim hotelima u gospodarstvu Republike Hrvatske kao smjernice za izradu što boljih web stranica koje će pozitivno utjecati na poslovanje samih hotela. Istraživanje može koristiti kako bi se dokazala povezanost između teorijskih postavki o povezanosti web prisustva hotela i njihovog poslovnog uspjeha dok empirijski dio rada može koristiti ka temelj za buduća istraživanja ili pak benchmarking poduzeća Colosseum d.d.. Na osnovi rada, hotelska poduzeća mogu razmisliti na korištenju poslovne inteligencije i izvještavanja na svim razinama poslovanja. Cilj bi bio utvrditi najbolje prakse na svim područjima poslovanja te ih implementirati kako bi se profit uspio maksimizirati.

## **1.7. Struktura rada**

Diplomski rad će se sastojati od šest osnovnih dijelova koji uključuju uvod i zaključak. U uvodu će biti predstavljen problem istraživanja, predmet istraživanja, istraživačke hipoteze, zatim cilj istraživanja i doprinos istraživanja.

Drugi dio će sadržavati osvrt na definiranje i korištenje poslovne inteligencije u turističkim poduzećima. Utvrdit će se najbolje prakse te zastupljenost poslovne inteligencije u hotelima na području republike Hrvatske.

Treći dio rada će se odnositi na pojam web analitike, njezinu definiciju, način provedbe, elemente koje istražuje, prednosti i nedostatke te koristi koje može pružiti poduzeću. S ovim dijelom će se zaključiti teorijski dio rada.

Četvrti dio rada će se odnositi na empirijsko istraživanje. Definirati će se svi elementi istraživanja kao što su tehnički elementi i elementi ponude smještaja. Formirati će se baza podataka na osnovu analize svih dostupnih web stranica.

Peti dio rada će se fokusirati na kreiranje izvještaja iz baze podataka, izvlačenja zaključaka, kreiranja modela optimalne web stranice te donošenja prijedloga najbolje prakse pri izradi web stranice.

Šesti dio rada će biti zaključak u kojemu će se definirati jesu li postavljene hipoteze istinite te je li rad ispunio sve zadane ciljeve.

Osim ovih dijelova rad će još sadržavati popis literature, sažetak na hrvatskom i engleskom jeziku, popis tablica i slika te popis literature koja je korištena za izradu rada.

## **2. Poslovna inteligencija u hrvatskim hotelima**

Pojam poslovne inteligencije (Business Intelligence) je nastao 1989. godine od strane američkog poslovnog analitičara Howarda Dresnera. Od trenutka svoje pojave pa do danas se ovaj pojam prometnuo u jedan od najvažnijih instrumenata poslovanja u suvremenim gospodarskim uvjetima. Mnogi stručnjaci i menadžeri smatraju da je poslovna inteligencija jedan od osnovnih preduvjeta uspješnog poslovanja. Razlog zbog kojeg se toliko značaj daje ovom pojmu leži u činjenici da se točna, kvalitetna i pravodobna informacija, koja je pretočena u poslovno znanje, može vrlo lako pretočiti u poslovni uspjeh. Kad govorimo o poslovnoj inteligenciji u hrvatskom gospodarstvu, može se primijetiti da postoji više različitih naziva, pa tako govorimo o pojmovima kao što su: poslovno izvještavanje, poslovna inteligencija, poslovno-obavještajna aktivnost, poslovno-obavijesna aktivnost, gospodarsko obavještavanje, poslovno-izvještajna aktivnost, poslovno istraživanje, upravljanje poslovnim informacijama, poslovno izvještavanje, poslovno obavještavanje, poslovne informacije, a vrlo često se koriste i izrazi kao poslovna špijunaža i špijuniranje konkurencije, što ipak može spadati u nezakonite aktivnosti pa je važno odrediti granicu između legalnih i ilegalnih aktivnosti.

Poslovna inteligencija (poslovno-obavještajna aktivnost) je obavještajna aktivnost u poslovnom svijetu koju planiraju, organiziraju i provode poslovni subjekti, pri čemu ta aktivnost podrazumijeva proces legalnog prikupljanja javnih i svima dostupnih podataka etičnim sredstvima, njihovu analizu i pretvaranje u gotove poslovno-obavještajne analize („znanje“) radi pružanja potpore čelništvu poslovnog subjekta s ciljem donošenja i realizacije što kvalitetnijih poslovnih odluka usmjerenih na očuvanje postojeće pozicije poslovnog subjekta u poslovnom okruženju, izbjegavanje bilo kakvih prijetnji i u konačnici na ukupni kvalitativni napredak poslovnog subjekta<sup>6</sup>. Prema dosadašnjim istraživanjima<sup>7</sup> poslovna inteligencija poduzećima donosi mnogo koristi poput efikasnijeg odlučivanja, zatim veću konkurentnost na tržištu te znatno veći rast prihoda u odnosu na poduzeća koja ne koriste poslovnu inteligenciju.

U posljednje vrijeme poslovna inteligencija postaje nezaobilazan, čak i strateški važan resurs menadžerima pri donošenju odluka. Prema istraživanju "Global Intelligence Alliance" (GIA)<sup>8</sup> iz 2005. godine u Europskoj uniji njezina zastupljenost iznosi između 73% i 96%, dok je na svjetskoj razini taj broj nešto manji od 90%, odnosno 87% na cjelokupnoj svjetskoj razini.

U Hrvatskoj je potpuno različita slika kad govorimo o zastupljenosti poslovne inteligencije u poduzećima. Prema istraživanju iz 2005. godine na uzorku od 85 poduzeća, utvrđeno je da samo 9% poduzeća ima vlastiti odjel za poslovnu inteligenciju dok se tek 44% ostalih poduzeća samo povremeno bavi poslovnom inteligencijom kroz različite poslovne procese<sup>9</sup>. Ipak, istraživanje iz 2010. godine je pokazalo trend rasta korištenja poslovne inteligencije unutar hrvatskih poduzeća pa je prema istraživanju na 84 poduzeća, s odazivom na anketu od 50%, zaključeno da 50% hrvatskih poduzeća ima odjel koji se bavi poslovnom inteligencijom<sup>10</sup>.

---

<sup>6</sup> Javorović, B., Bilandžić, M. (2007.): Poslovne informacije i Business Intelligence, Golden marketing, Zagreb.

<sup>7</sup> Weiss, A. (2005.): Justifying CI Activities, Competitive Intelligence Magazine, Vol. 8, Br. 6.

<sup>8</sup> Global Intelligence Alliance (2005.): Developing an Intelligence System, GIA White Paper 1/2005.


<sup>9</sup> Ivančević, D., Jurišić, M. (2005.): „Research study: State of competitive intelligence in Croatian companies“, Zagreb.

<sup>10</sup> Zebić, O. (2010.): Poslovno obavještavanje i oblikovanje poslovnih strategija hrvatskih poduzeća, specijalistički poslijediplomski rad, Sveučilište u Zagrebu, Ekonomski fakultet.

Posljednje i najveće provedeno istraživanje iz 2011. godine<sup>11</sup>, koje je provedeno na uzorku od 1000 poduzeća je pokazalo sljedeće rezultate:

Graf 1. Zastupljenost BI u hrvatskim poduzećima

### Zastupljenost BI u hrvatskim poduzećima




Izvor: Poslovna inteligencija u hrvatskom gospodarstvu, 2012.

Zaključak istraživanja je da je korištenje poslovne inteligencije u hrvatskom gospodarstvu u blagom porastu, ali je ipak još daleko od europskog i svjetskog prosjeka. Posebno zabrinjava podatak što je i dalje veći broj poduzeća koja se uopće ne bave nikakvom vrstom BI (Business Intelligence) aktivnosti, nego onih poduzeća koja imaju zaseban BI odjel. Također, zanimljiva je i situacija zastupljenosti BI prema sektoru poslovanja.

<sup>11</sup>Bilandžić, M., Čulig, B., Lucić, D., Putar-Novoselac, M., Jakšić, J. (2012.): Business Intelligence u hrvatskom gospodarstvu, Sveučilište u Zagrebu.

Graf 2. Zastupljenost BI prema djelatnosti



Izvor: Poslovna inteligencija u hrvatskom gospodarstvu, 2012.

Prema ovom istraživanju, najveći broj poduzeća koja koriste poslovnu inteligenciju se bavi financijama i bankarstvom (84%) te informacijama i komunikacijama (82%). Ovi sektori su ujedno i najbrže rastući sektori u državi pa je i jasno zašto su takvi rezultati. S druge strane, rezultati vezani za sektor turizma su vrlo poražavajući, tek 10% poduzeća ima zaseban sektor za poslovnu inteligenciju dok se 50% poduzeća u turizmu bavi bar nekakvim aktivnostima vezanim za poslovnu inteligenciju.

Iz ovog istraživanja možemo zaključiti da turistička poduzeća u hrvatskoj imaju još mnogo prostora za napredak u korištenju poslovne inteligencije u poslovanju. To je jedna od vrlo važnih stavki u održavanju koraka s konkurencijom, pogotovo na svjetskoj razini.

### 3. Analiza web sadržaja hotelskih stranica

Primjena interneta u marketinškoj komunikaciji imperativ je u suvremenoj hotelskoj praksi. Prednosti interneta poput dostupnosti, praktičnosti, interaktivne komunikacije i vremenske

neograničenost<sup>12</sup> utjecali su na činjenicu da je internet postao primarni alat kojim se moderni putnici služe pri odabiru destinacije svojih putovanja i smještaja. S obzirom na tu činjenicu, sadržaj web stranica hotelskih poduzeća kao i njihov dizajn, interaktivnost, dostupnost i funkcionalnost su jedan od ključnih faktora u fazi odlučivanja turista pri izboru smještaja na putovanju.

Web stranice hotela su tako postale jedan od najvažnijih kanala marketinške komunikacije. Za turiste su one tako postale glavni izvor informacija, mjesto na kojem mogu saznati sve što ih zanima o samom smještaju poput lokacije, cijene, samog izgleda, zatim popratnih sadržaja ili okolnih atrakcija. S druge strane, za ponuđače hotelskog smještaja web stranice su postale glavni izvor generiranja prometa te vrlo važan alat za promociju, ali i prikupljanje podataka o web ponašanju turista.

Analiza sadržaja je istraživačka opservacijska metoda koja se koristi za sistematsku procjenu sadržaja svih formi zabilježenih komunikacija<sup>13</sup>. Pruža objektivni, znanstveni i kvantitativni opis sadržaja. Osnovna tehnika analize sadržaja se odnosi na prebrojavanju broja pojavljivanja prethodno definiranih kategorija mjerenja u promatranom sadržaju. Da bi analiza sadržaja bila efektivna mora zadovoljiti nekoliko kriterija:

- Potrebno je uzeti reprezentativan, nasumično odabran uzorak
- Mjerne jedinice, odnosno kriteriji analize moraju biti jasno definirani – ove jedinice mogu biti specifične kao npr. riječ, fraza, tema, odlomak, simbol, slika, tablica ili pak jednostavne kao postojanje ili nepostojanje određene tvrdnje ili događaja.
- Kategorizacija podataka mora biti sistematična – mora biti jasno pripada li ili ne pripada određeni predmet određenoj kategoriji

Analiza sadržaja je često korištena metoda kod procjene i poboljšavanja web mjesta. Web sadržaj je postao vrlo bitan aspekt izrade web stranica hotela, stoga web sadržaj i njegova

---

<sup>12</sup> Kim, Y. H., Yuan, J., Goh, B. K. i Antun, J. M. (2009.): Web Marketing in Food Tourism: A Content Analysis of Web Sites in West Texas, *Journal of Culinary Science & Technology*, God. 7, Br. 1, str. 52–64

<sup>13</sup> Kolbe, R. H. and M. S. Burnett (1991): Content analysis research: An examination of applications with directives for improving research reliability and objectivity, *Journal of Consumer Research*, str. 243.-250.

prezentacija postaju sve važniji. Dizajn i prezentacija web sadržaja bi trebali privući posjetitelje, informirati ih te potaknuti na rezervaciju smještaja.

### 3.1. Web mjesto

Web mjestom ili web sjedištem se smatra kolekcija međusobno povezanih web stranica koje se nalaze na HTTP poslužitelju na World Wide Webu, kojoj korisnici unutar web preglednika pristupaju putem jedinstvene adrese ili URL-a (akronim za engl. Uniform Resource Locator)<sup>14</sup>

Strukturu web sjedišta se može promatrati na različite načine, a kao jedna od najefikasnijih se smatra model autora Jeffery-a Rayporta i Bernarda Jaworskog. Njihov model se sastoji od sedam elemenata, tzv. 7C model. Elementi od kojih se sastoji su:

- sadržaj (content)
- komunikacija (communication)
- kontekst (context)
- zajedništvo (community)
- prilagodljivost (customization)
- povezanost (connection)
- poslovanje (commerce)

Sadržaj ili content web mjesta je u posljednje vrijeme postao jedna od centralnih tema kad je riječ o izradi web stranica i njihovoj interakciji sa posjetiteljima. Suvremeni stručnjaci smatraju da je web sadržaj glavni element i da o njegovoj kvaliteti ovisi posjećenost stranici i interakcije korisnika s njom. Činjenica koja ide u prilog toj tezi je i ubrzani razvoj funkcije menadžera sadržaja, koji postaje neizbježan u internet marketingu. Posjetitelji web stranica su izloženi širokoj ponudi web stranica te na taj način imaju veliku mogućnost izbora, stoga je važno da se, u ovom slučaju, ponuđač hotelskog smještaja istakne među konkurencijom, a dobar web sadržaj je jedna od osnovnih stvari za uspjeh.

---

<sup>14</sup> Buzov, V., Buzov, I., Balenović, N. (2013.): Odnos s kupcima putem elektroničke pošte u hrvatskim hotelima, Zbornik radova: "Izazovi današnjice: Turizam danas - za sutra"



Prema istraživanju poduzeća Tambourine<sup>15</sup>, koje je specijalizirano za povećanje prihoda hotela diljem svijeta, postoji nekoliko važnih psiholoških faktora i utjecaja koje sve uspješne web stranice hotela imaju na posjetitelja da bi on izvršio rezervaciju. Jedan od najvažnijih faktora je stvaranje emotivne povezanosti. Tu činjenicu objašnjavaju istraživanjem Neurosciencemarketing.com koji kaže da potrošači vrlo često donose odluke kad emocije nadvladaju racionalno razmišljanje. Dakle, ponuđači hotelskog smještaja bi trebali na svojim web stranicama imati sadržaj koji će “natjerati” posjetitelja na donošenje odluke vodeći se emocijama, a ne racionalnim razumom. Zatim, stvaranje osjećaja hitnosti koji je najbolji pokretač kupaca da konvertiraju (naprave rezervaciju). Fraze poput: ograničena ponuda, ograničen broj soba ili odbrojavajući oglasi stvaraju kod potrošača osjećaj da će propustiti sjajnu ponudu ako ne rezerviraju svoj smještaj što prije. Maksimalno jednostavan proces rezervacije ima snažan utjecaj na povećanje rezervacija. Potrošači se ne vole previše truditi kad je riječ o rezerviranju, uvijek idu linijom manjeg otpora i tzv. “defaulting” određenih elemenata rezervacije je upravo ono što će privući potrošača, odnosno posjetitelja da prije napravi rezervaciju na web stranci. Dakle, vrlo je važno da se rezervacijski proces može odraditi u samo par koraka, da je potpuno predvidljiv i da potrošaču ne ostavlja nikakve nedoumice u nijednom koraku jer će u tom slučaju odustati od rezervacije i potražiti alternativu.

Korištenje dokaza na društvenim mrežama da bi utjecali na odluke potrošača su jedna od osnovnih strategija svih hotela, ali oni najuspješniji se koncentriraju na psihološki utjecaj svojih objava. Jedan od takvih psiholoških fenomena koji se pojavio s razvojem društvenih mreža je Fear of missing out (FOMO), termin koji se odnosi na strah propuštanja nečeg važnog. Hotelska poduzeća pomoću društvenih medija iskorištavaju ovaj fenomen kao prednost pomoću različitih tehnika. Npr. broj ljudi koji je u posljednjih nekoliko sati/dana rezervirao smještaj ili broj preostalih soba određenog tipa i broja zvjezdica. Na taj način žele potrošačima pokazati da su i ostali potrošači već rezervirali smještaj što će utjecati na validaciju njihove odluke da također naprave rezervaciju.

---

<sup>15</sup> Tambourine Marketing agency (2005.): The Surprising Psychology Behind Successful Hotel Websites: Part One.

Preuzeto: [14.02.2017.]

Posljednji faktor je utjecaj na smanjenje osjećaja krivnje kod potrošača. Jedan od čestih događaja je da nakon rezervacije, potrošač promijeni svoje planove, možda požali svoju odluku i otkaže rezervaciju. Da bi se to spriječilo važno je da hotelijeri odmah po završetku rezervacije ohrabre potrošača da je napravio dobru odluku i ukažu mu na prednosti svoje odluke, odnosno prednosti koje je ostvario rezervirajući smještaj upravo u njihovom hotelu. Jedna sjajna tehnika je omogućiti klijentima mogućnost da podijele na društvenim mrežama vijest da su rezervirali smještaj u njihovom hotelu, na taj način će puno teže doći do otkazivanja smještaja, a također je svaka objava i besplatna reklama za njihov hotel.

S druge strane postoji nekoliko ključnih stvari koje će obeshrabriti potrošača, odnosno posjetitelja web stranice da rezervira smještaj u hotelu. Prema istraživanju agencije PCA Predict, najveći problem su tzv. “skrivenе cijene”, dakle situacija kad cijene nisu jasno naznačene ili se pri plaćanju rezervacije pojavljuju neki novi troškovi koji prethodno nisu bili naznačeni. U tim situacijama potrošači gube povjerenje u ponuđača smještaja i često budu nepovratno izgubljeni. Zatim slijedi problem sa stranicama koje nemaju recenzije. Potrošači se pri rezervaciji smještaja često pouzdaju u iskustva drugih posjetitelja s hotelom te na osnovi tih iskustava procjenjuju uslugu te u konačnici donose odluku.

Komplicirane i duge rezervacijske forme odbijaju potrošače od rezervacije. Kao što je prethodno spomenuto, potrošači uvijek idu linijom lakšeg otpora i ne žele trošiti puno vremena na ispunjavanje dugih formi već traže što lakši način rezervacije, također duge procese rezervacije smatraju nesigurnim te se nerijetko radi o zastarjelim rezervacijskim sistemima što je također loš znak za potrošače.

Nepostojanje slika smještaja je također negativno za poboljšanje broja rezervacija. Stranice koje nemaju slike hotela su uglavnom zastarjele, potrošači ih nerijetko smatraju prevarama i u širokom luku izbjegavaju te ne žele rezervirati smještaj “na slijepo”. U današnje vrijeme mobilni internet sve više preuzima dominaciju, potrošači vrlo često rezerviraju svoje odmore preko mobitela dok idu na posao ili s posla i web stranice koje nemaju responzivan dizajn se u tom slučaju nalaze u problemima. Zbog otežane navigacije i nepreglednosti sadržaja potrošači uglavnom odustaju od rezervacije i traže alternativna rješenja. Osim toga, jedan od velikih problema je i dugo vrijeme učitavanja stranice. Često dizajneri stranice preoptereće web

stranice s velikom količinom sadržaja i vrijeme učitavanja traje predugo te potrošači odustaju od pregleda stranice, stoga se preporuča pri izradi web stranice obratiti posebnu pozornost na količinu multimedijalnih sadržaja da ne bi doveli do predugog vremena učitavanja sadržaja.

Prema nekim istraživanjima čak 80% posjetitelja odustanu od rezervacije zbog dugih i kompliciranih rezervacijskih formi i obrazaca. Zanimljivost je da kad se tiče rezervacija na osnovi recenzija smještaja, čak 35% više žena u odnosu na muškarce rezervira smještaj na osnovi iskustava prijašnjih posjetitelja hotela. Ono što je vrlo važno jest da web stranica kreira doživljaj komfora i uživanja, isti onaj koji će posjetitelj osjetiti kad uđe u hotel.

### **3.2. Utjecaj sadržaja web stranice hotela na donošenje odluke turista**

U posljednjem desetljeću internet se profilirao kao jedan od najvažnijih izvora informacija za turiste, čak je otišao korak dalje te postao jedno od glavnih sredstava komunikacije turista i ponuđača smještaja. Razlog tomu je vrlo jednostavan, s obzirom da se turistička usluga isporučuje uglavnom u mjestu udaljenom od doma, vrlo često potpuno nepoznatom te uključuje mnogo rizika poput financijskih, fizičkih, psihičkih i socijalnih rizika. Sve te činjenice utječu na velika ulaganja vremena truda i financijskih resursa od strane turista kako bi donijeli odluku.

S jedne strane turisti pretražuju informacije o destinacijama putovanja, smještaju, iskustvima ostalih turista, raspituju se za cijene i aranžmane te u konačnici rezerviraju smještaj. S druge strane, ponuđači smještaja i turistički djelatnici koriste informacije s interneta da bi dobili što jasniji uvid u ono što potrošači traže te tako mogu odgovoriti na njihove zahtjeve u procesu razvoja proizvoda<sup>16</sup>.

Da bi uspješno prilagodili svoju ponudu, turistički djelatnici moraju znati gdje turisti pronalaze informacije, koliko su im značajni kanali iz koji ih dobivaju te koji faktori ih potiču na odluku o putovanju, odnosno izboru smještaja. Dakle, da bi razumjeli što turist želi,

---

<sup>16</sup> Fratu, D. (2011.): Factors of influence and changes in the tourism consumer behaviour, Bulletin of the Transilvania University of Braşov, God. 4, Br. 1, str.119.–126.

turistički djelatnici moraju biti upoznati s procesom donošenja odluke o putovanju turista. Taj se proces sastoji od tri faze<sup>17</sup>:

- Prva faza je proces prije donošenja odluke i donošenje odluke
- Druga faza je procjena nakon kupnje
- Treća faza je buduće donošenje odluka

Prva faza je i najvažnija faza, ostale dvije faze ovise o njoj. U prvoj fazi je turist izložen najvećem broju informacija, još nije odlučio o destinaciji i smještaju već istražuje sve dostupne informacije, planira cjelokupno putovanje i aktivnosti na putovanju. Turist je u ovoj fazi izložen raznim utjecajima i može lako promijeniti odluku, stoga je važno da turistički djelatnici iskoriste svaku priliku da uvjere turista da je baš njihova destinacija, odnosno smještaj idealni za njihovo sljedeće putovanje.

U ovoj fazi turist prikuplja informacije iz raznih izvora kako bi u konačnici odlučio koju će destinaciju i smještaj odabrati za sljedeće putovanje. Informacije koje turist prikuplja dijelimo na dva različita izvora<sup>18</sup>:

- Unutarnji izvor informacija
- Vanjski izvor informacija

Kad govorimo o unutarnjim informacijama, ponajprije se taj termin odnosi na informacije pohranjene u memoriji samog turista i one su manje značajne u procesu donošenja odluke, turist se uglavnom više oslanja na vanjske izvore informiranja. Kao najvažnije vanjske izvore informiranja možemo nabrojiti savjetovanje s prijateljima i rodbinom, specijaliziranu literaturu, savjetovanje stručnjaka, ali možda najbitniji izvor je internet.

Turistu internet omogućava dostupnost većine informacija koje su mu potrebne poput; raspoloživosti smještaja, cijene smještaja, vizualnog prikaza smještaja, zatim komunikaciju s turističkim djelatnicima te mogućnost rezervacije i poništavanja rezervacije<sup>19</sup>.

---

<sup>17</sup> Moutinho, L. (2000.): Strategic Management in Tourism, CABI Publishing, Wallingford, str. 73.

<sup>18</sup> Ho, C. I.; Lin, M. H. i Chen, H. M., (2012.): Web users' behavioural patterns of tourism information search: From online to offline, Tourism Management, God. 33, Br. 6, str.1468.–1482.

Osim ovakvog načina pogleda gdje turist prikuplja informacije iz unutarnjih ili vanjskih izvora informacija, kao način prikupljanja informacija možemo gledati i preko distribucijskih kanala. Razlikujemo:

- Direktni distribucijski kanali
- Indirektni distribucijski kanali

Direktni kanali povezuju turiste i turističke djelatnike direktno i bez posrednika. U ovim kanalima se direktno razvija razmjena informacija i održavanje kontakta između turističkih djelatnika i turista. Za razliku od ovog kanala, u indirektnom kanalu postoji širok spektar posrednika koji komuniciraju i prodaju usluge turistima u ime turističkih djelatnika, odnosno ponuđača smještaja.

Turistu je važno da što brže i što lakše dođe do informacija na internetu, stoga je važno da se ispune tri uvjeta kako bi potraga za informacijama bila što efikasnija<sup>20</sup>:

- Jednostavnost pristupa informacijama
- Jednostavnost upotrebe
- Pouzdanost informacija

Analizirajući ova tri uvjeta koja su važna kako bi turist lako i efikasno došao do informacija, možemo zaključiti da bi web stranice ugostiteljskih objekata trebale biti intuitivne, interaktivne i kompatibilne s ostalim mehanizmima pretraživanja, a prije svega u skladu s potrebama turista kako bi mu omogućili pronalazak traženih informacija. Turisti očekuju da web stranice budu informativne, interaktivne i atraktivne<sup>21</sup>.

Dakako, važno je da se i ostale dvije faze ne podcijene jer mogu imati velikog utjecaja na povratak turista u odabranu destinaciju, odnosno smještaj ako bude zadovoljan cjelokupnom uslugom.

---

<sup>19</sup> Andrić, B. i Ružić, I. (2010.): E effect of e-marketing on consumer behavior in hospitality, *Tourism & Hospitality Management* 2010, Faculty of tourism and hospitality management, Opatija, str. 692–706.

<sup>20</sup> Kozak, M. i Decrop, A. (2009.): *Handbook of Tourist Behavior: theory & practice*, Taylor & Francis, New York, str. 213

<sup>21</sup> Chu, R. (2001.): What online Hong Kong travelers look for on airline/travel websites?, *International Journal of Hospitality Management*, God. 20, Br. 1., str. 95.–100.

### 3.2.1. Osnovni elementi web stranice hotela

Prema mišljenju ekonomista Zarabare<sup>22</sup> postoji nekoliko osnovnih elemenata koje svako turističko poduzeće mora imati na svojim web stranicama, odnosno to su elementi koje svaki korisnik očekuje da će pronaći na web stranici. U slučaju da oni ne postoje tj. da ih web stranica ne sadržava, velika je vjerojatnost da će korisnik izbjeći eventualnu rezervaciju preko tog web mjesta. Dakle, neki od osnovnih elemenata su:

- Podaci o hotelu – eventualnom posjetitelju je vrlo važno da sazna podatke o veličini hotela, je li se radi o malom obiteljskom hotelu ili možda o hotelskom lancu. Osim toga važno je da sadrži i podatke o kategoriji hotela te svim uslugama koje se pružaju kao i lokacija hotela i upute za dolazak do hotela. Mapa s lokacijom hotela je vrlo važna i smatra se neizbježnim elementom web stranice.
- Podaci o smještaju – jedan od ključnih elemenata pri rezervaciji smještaja je vizualni prikaz smještaja i informacije o smještaju, ako oni ne postoje posjetitelj će smatrati da je kvaliteta smještaja loša i neće rezervirati smještaj. Zarabara preporuča da je osim dobrih informacija potrebno objaviti i seriju slika smještaja da bi se posjetitelji još bolje uvjerali u samo stanje smještaja.
- Podaci o prehrani – informacije o pružanju usluge prehrane u hotelu, važno je dati informacije o restoranu, jelima koja se služe te uz informacije predložiti slike
- Podaci o dodatnim uslugama – popis svih ostalih usluga koje hotel nudi, važno je da se naglasi koje su usluge uključene u cijenu smještaja, a koje zahtijevaju dodatno plaćanje
- Podatci o destinaciji – u ovom dijelu je važno pružiti informacije o destinaciji u kojoj se smještaj nalazi, nabrojiti sve kulturne i društvene znamenitosti, prirodne ljepote i sugerirati aktivnosti kojima bi se posjetitelji mogli baviti u slobodno vrijeme. Dakako, opet je važno predložiti slike uz informacije.

---

<sup>22</sup> Zarabara, C. (2009): Strategie di web marketing per il settore turistico-alberghiero (english version), Hoepli, Milano.

- Često postavljene pitanja (FAQ) – vrlo važna sekcija na webu koja posjetiteljima omogućava dobivanje odgovora na sva pitanja koja su im ostala nejasna pregledavanjem web stranice. Također, zaposlenici hotela mogu na ovaj način uštediti puno vremena jer ne moraju odgovarati na brojne upite koje bi im posjetitelji slali.

Dakako, ovi elementi ne garantiraju pružateljima smještaja da će posjetitelj rezervirati smještaj preko njihove web stranice, ali u slučaju da ih nemaju na svojoj stranici puno je veća vjerojatnost da će ih preskočiti i nastaviti potragu za smještajem na web stranicama nekog drugog pružatelja smještaja.

### **1.3. Web analitika**

Pod pojmom web analitike smatramo mjerenje, prikupljanje, analizu i izvještavanje podataka s web mjesta radi boljeg razumijevanja i poboljšanja korištenja promatranog web mjesta<sup>23</sup>. Web analitika je prikupljanje podataka i izvještavanje o korištenju web stranice tako da bi poduzeća mogla bolje razumjeti kompleksnost interakcija između akcija web posjetitelja i i ponude web mjesta kao i korištenje tih podataka da bi se pojačala lojalnost klijenata i povećala online, ali i offline prodaja<sup>24</sup>.

Također, neki autori definiraju web analitiku kao metodološko proučavanje online ili offline uzoraka i trendova. Koristi se za praćenje ključnih metrika te analizu kretanja i korištenja web stranice od strane posjetitelja.

Iako je web analitika u osnovi mjerenje i praćenje prometa na web mjestu, zapravo je krivo shvaćanje da ona služi samo statističkim izvještajima o uspješnosti web mjesta. Web analitika pruža uvid u širok spektar informacija o online poslovanju i klijentima. Na osnovu web analitike vlasnik web mjesta može vidjeti na koji način su posjetitelji došli do njegove stranice, kakve su njihove aktivnosti kad dođu na stranicu, zatim koliko su vremena proveli na web stranicama te može zaključiti zbog kojih su razloga napustili stranicu. Koristeći ove informacije vlasnik web mjesta može zaključiti koje su prednosti, a koji nedostaci njegovog

---

<sup>23</sup> Web Analytics Association Committee (2007.): Web Analytics Definitions, Wakefield, str. 3.

<sup>24</sup> Guy Creese, Aberdeen Group

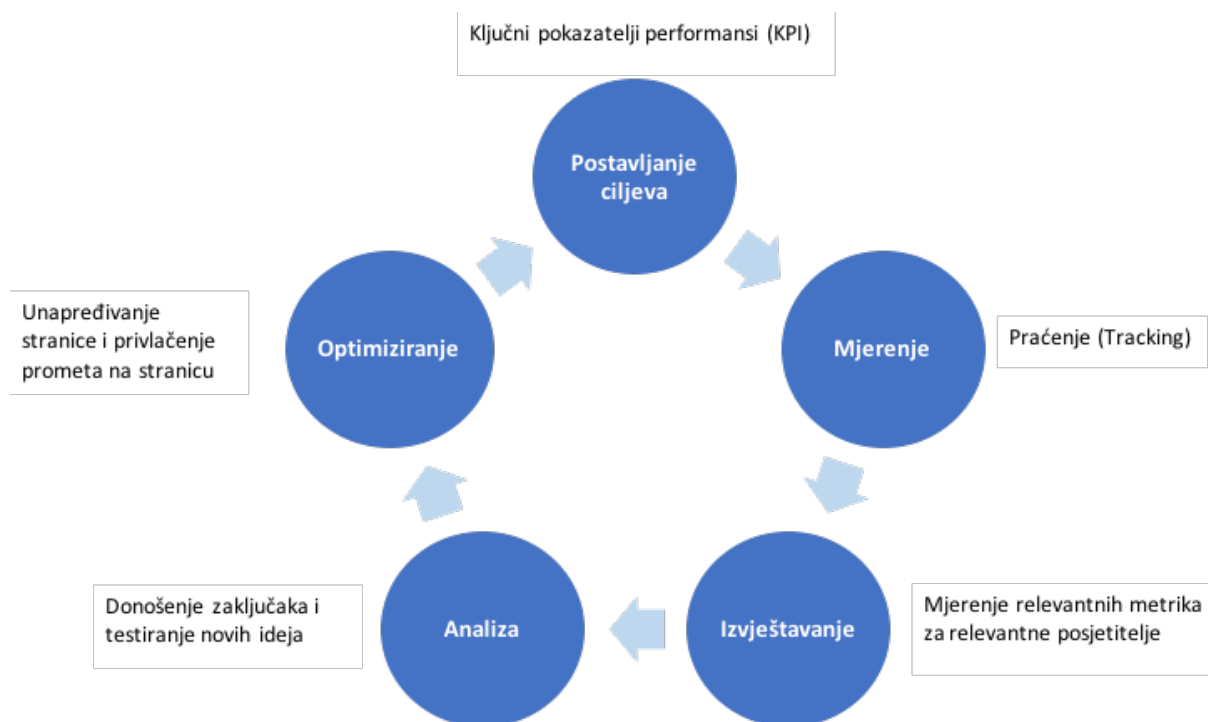
weba, što korisnike najviše privlači, a što ih odbija od ostvarivanja konverzije itd. Prilagođavanjem web stranica na osnovu podataka koji su mu na raspolaganju vlasnik web mjesta može pretvoriti svoje posjetitelje u lojalne klijente. Dakle, web analitiku treba shvatiti kao priliku za poboljšanje uspješnosti prometa na web stranici tj. web mjestu. Primarni cilj web analitike je optimizacija web mjesta kako bi ono pružilo što bolje korisničko iskustvo posjetiteljima web mjesta. Proces web analitike se odvija u nekoliko koraka:

- Određivanje poslovnih ciljeva i određivanje ključnih pokazatelja uspješnosti (Key Performance Indicators - KPI)
- Mjerenje i prikupljanje odgovarajućih i točnih podataka
- Izvještavanje
- Analiza podataka i testiranje alternativa
- Implementacija saznanja

Važno je napomenuti da analitika nije vezana isključivo uz web stranice. Podaci se mogu prikupljati i sa društvenih mreža, mobitela, e-mailova...



Slika 1. Proces web analitike



Izvor: [www.bigdataexpo.net](http://www.bigdataexpo.net), 2017.

### 1.3.1. Web analitika i optimizacija konverzija

Kad govorimo o web analitici i optimizaciji konverzija jedna od najvažnijih stvari je dobra priprema. Nije samo važno prikupljanje podataka, važno je znati koje podatke ćemo koristiti, odnosno koji podaci su nam relevantni. Nakon što se podaci prikupe treba ih analizirati i te ćemo na osnovu dobivenih rezultata znati što na stranici trebamo optimizirati. Osnovu web praćenja na internetu čine tzv. “kolačići” (cookies). Maleni isječak koda koji prati kretanje individualnog korisnika i “snima” njegovu aktivnost na web stranici. O njima je vođeno mnogo polemike jer su vrlo često zloupotrebljavani od strane “spywarea” stoga većina stranica pri ulasku na stranicu ima upozorenje da se posjetitelj slaže s politikom privatnosti web stranice. Kolačići pružaju podatke programima za analitiku i stoga su jako važni.

Da bi proces analitike podataka web mjesta bio uspješan važno je da se prije samog početka odredi koji su ciljevi (goals) vlasnika web mjesta, zatim koji su to događaji (events) tzv. mikrokonverzije pomoću kojih će se ti ciljevi ostvariti te koji su to ključni pokazatelji uspješnosti (KPI). Npr. ciljevi za neku hotelsku web stranicu bi bili povećanje rezervacija smještaja ili smanjenje marketinških troškova dok bi KPI stopa konverzija, trošak po posjetitelju ili prosječna vrijednost rezervacije.


Ciljevi su najvažniji jer pomoću njih se određuje uspješnost web mjesta. Ciljevi mogu biti različiti, ali najčešće su to one radnje na webu koje donose neku vrstu prihoda poduzeću. Vrlo često se dogodi situacija da je postizanje krajnjeg cilja podijeljeno na nekoliko koraka, te korake nazivamo događajima ili mikrokonverzijama. KPI pomažu da se uvidi koji su to faktori na koje se može utjecati. Ako je npr. cilj povećanje prihoda, tada se mogu gledati načini na koje se može povećati stopa konverzije. Jedan od načina povećanja stope konverzije bi bio ponuda popusta. U tom slučaju će vjerojatno doći do povećanja broja rezervacija, ali će pasti vrijednost po rezervaciji. Ili se može pogledati na koji se način može povećati vrijednost po rezervaciji na način da stopa konverzije ostane ista, a da se poveća prihod od svake rezervacije. KPI i eventi daju detaljan uvidaj u faktore i korake na koje se može utjecati da bi se ostvarili zadani ciljevi. Oni omogućuju da na mikro razini sagledamo ono što će utjecati na performanse i rezultate na makro razini.

Analiza svakog koraka prema ostvarivanju krajnjeg cilja, tzv. funnel (lijevak) analiza ili analiza puta, važna je iz razloga da bi se otkrilo gdje u procesu ostvarivanja krajnjeg cilja nastaju problemi. Npr. za hotelsku web stranicu krajnji cilj bi bio da posjetitelj rezervira smještaj. Svaki događaj (event) u procesu rezervacije se može analizirati kao konverzijski korak, pa tako možemo imati sljedeće evente:

- Pretraživanje slobodnih hotelskih kapaciteta unutar željenog datuma na području koje posjetitelj želi posjetiti
- Uspoređivanje cijena i kvalitete raspoloživog hotelskog smještaja
- Odabir smještaja i ulazak u proces rezervacije
- Unos osobnih i podataka o plaćanju
- Slanje zahtjeva za rezervacijom i potvrda rezervacije smještaja (konverzija)

Na svakom od ovih koraka se očekuje sve manji broj posjetitelja te se zato i zove analiza lijevka. Povećanje broja posjetitelja na svakoj fazi bi u konačnici utjecalo i na povećanje broja konverzija.

Slika 2. Funnel analiza



Izvor: Online Marketing Essentials, 2012.

Cijeli proces analize lijevka započinje s fazom uvjeravanja gdje se uvjerava posjetitelje bilo marketingom ili preko drugih alata da posjete web stranicu. Na svakoj od faza dio posjetitelja odustaje radi određenih razloga, bilo da je riječ da je posjetitelj u različitoj fazi procesa kupovine, ostalih osobnih razloga ili je naišao na problem s ponudom i problemom na web stranici koji ga je naveo na odustajanje od rezervacije smještaja.

### 1.3.2. Praćenje i prikupljanje podataka

Trenutno razlikujemo dva glavna načina prikupljanja podataka za web analitiku, to su:

- Log-file analiza
- Označavanje stranice (Page tagging)

Software za log-file analizu čita zapise, koje nazivamo “log-datoteke“, na web serveru koji bilježi sve klikove koji su se na serveru dogodili. Dok kod označavanja stranice se informacije šalju tzv. third-party serveru gdje se generiraju sve statistike. Pretraživač (browser) kreira JavaScript kod koji komunicira s programom za praćenje pritom stvarajući oznake stranica (page tags).

Pomoću pixel označavanja možemo još pratiti e-mail kampanje na način da se pri učitavanju slika učitava i mala slika koja prati aktivnost korisnika.

Kad govorimo o prednostima log-file analiza nad “page tagging“ analizom tad se može istaknuti da se provodi od strane web servera tako da su sirovi podaci za analizu uvijek spremni dok kod “page tagging“ se mora provesti izmjena koda web stranice da bi došli do podataka. Log-file podaci su jako točni jer bilježe svaki klik za razliku od “page tag“ podataka koji nisu toliko točni i u slučaju da korisnikov browser ne podržava JavaScript on neće moći prikupljati podatke uopće. Također, log-file podaci su standardizirani pa nema nikakvih problema pri promjeni ponuđača usluga analize dok je “page tagging“ vlasništvo pojedinog ponuđača usluga analize pa tako promjena znači i gubljenje povijesnih podataka. Prednost log-file analize je i što bilježi i uspješne i neuspješne zahtjeve dok “page tagging“ bilježi samo uspješne.

S druge strane, prednosti “page tagging“ su u tome što se pomoću JavaScripta na jednostavniji način može zabilježiti više podataka. Npr. da bi ispratili koji su proizvodi kupljeni, kod log-file analize bi morali mijenjati URL što jako nezgodno. “Page tagging“ može izvještavati o događajima kao npr. interakcijama s flash sadržajem dok log-file analiza nema te mogućnosti. “Page tagging“ mogu koristiti poduzeća koja ne upravljaju sa svojim serverima i obično pruža veću razinu podrške zbog sudjelovanja “third-party“ usluge, dok se software za log-file analizu uglavnom vode unutar organizacije.

Zbog različitih metoda prikupljanja podataka, podaci između ove dvije metode se razlikuju pa se ponekad obje metode koriste za analizu web stranice.

Za svakog vlasnika web mjesta nakon postavljanja web stranice i praćenja važno je odrediti koji su to ciljevi njegovog posla te što točno želi mjeriti. Mjerenje se provodi pomoću web metrika. Razlikujemo tri osnovna tipa metrika, to su:

- Count (broj) – osnovna jedinica mjere, uglavnom se odnosi na cijeli broj npr. Broj posjetitelja: 12 000
- Ratio (omjer) – uglavnom predstavlja jedan broj podijeljen s drugim i vrlo često nije cijeli broj. Primjer omjera je Broj pregledanih stranica po posjetitelju (Pages per visitor).
- Key Performance Indicators (Ključni pokazatelji uspješnosti) – mogu biti i broj i omjer, ali su uglavnom omjer. Brojevi i omjeri mogu biti korišteni kod svih tipova stranica dok KPI ovise o tome što je važno za pojedinu web stranicu i poslovnu strategiju.

Osim ove tri osnovne metrike, možemo još dodati metriku koja služi za pojmove koji su opisani konceptima, a ne brojevima:

- Dimensions (Dimenzije) – generalni izvor podataka koji može biti korišten da bi se definirali različiti tipovi segmenata i brojeve te predstavlja fundamentalnu dimenziju posjetiteljevih ponašanja i dinamike same web stranice.

Metrike se mogu odnositi na tri različita polja. To su:

- Agregirana – ukupan promet na web stranici u nekom određenom periodu vremena.
- Segmentirana – podset prometa na web stranici u nekom određenom periodu vremena, filtriran na način da bi se dobili dublji analitički uvidi.
- Individualna – aktivnost pojedinog posjetitelja web stranice u određenom periodu vremena.

Kad govorimo o osnovnim pojmovima web analitike, stranica (Page) je analitički definirana jedinica sadržaja, većina analitičkih alata dozvoljavaju klijentu da sam odredi što će se kvalificirati kao stranica.

Što se tiče mjerenja publike koja posjećuje web mjesto, može se mjeriti broj pregleda stranica (Pageviews) koji govori koliko je stranica posjetitelj pregledao prilikom svog posjeta.

Stopa napuštanja stranice (Bounce rate) govori koliki je broj posjetitelja napustio web mjesto nakon što su pogledali samo jednu stranicu.

Metrika broj stranica po sesiji (Pages/Session) prikazuje koliki je broj stranica posjetitelj pregledao tijekom jedne sesije.

Informacije o demografskim pokazateljima (Demographic info) daju podatke o spolu i godinama posjetitelja.

Osim ovih metrika, informacije o uređajima (Devices) daju uvid u uređaje s kojih korisnici pristupaju web mjestu što može biti vrlo važno za optimizaciju web mjesta i izradu responzivnih web stranica.

Kad govorimo o akvizicijama, važna metrika je izvor prometa. On nam govori s kojih izvora posjetitelji najčešće dolaze pa tako razlikujemo nekoliko izvora:

- Organski promet je promet koji dolazi sa tražilica poput Googlea, Binga ili Yahooa. Promet s društvenih mreža je vrsta prometa u kojoj posjetitelji na web mjesto dolaze preko raznih društvenih platformi.
- Referral promet dolazi s onih web mjesta na kojima postoji link na vlasnikovo web mjesto.
- Direktni promet je promet koji vodi direktno na web mjesto, dakle kad posjetitelj direktno u pretraživač upiše URL web mjesta.

Izvor/Medij je metrika koja daje uvid u sve izvore s kojih promet dolazi na web mjesto, svojevrsna usporedba svih izvora prometa.

Kad govorimo o web sadržaju, dvije su osnovne metrike koje se nameću kao najvažnije:

- Landing stranice su prve stranice na koje posjetitelj dolazi, uglavnom su to homepage stranice. Praćenjem metrike može se utvrditi koje stranice imaju najviše posjećenosti, gdje se posjetitelji najviše zadržavaju i gdje rade najviše radnji koje smatramo korisnima, može se zaključiti koji je sadržaj posjetiteljima najrelevantniji te se shodno tome prilagoditi sav sadržaj na web mjestu.
- Druga metrika je brzina web stranice koja se odnosi na brzinu učitavanja sadržaja na web stranici. Praćenjem ove metrike se može utvrditi koje stranice imaju poteškoća s učitavanjem, a koje imaju visoku brzinu učitavanja te prema tome provesti optimizaciju stranica. Stranice koje se sporo učitavaju često izazivaju negativne reakcije kod posjetitelja te oni vrlo brzo odustaju od pregleda stranice. Takve stranice obično imaju visoku stopu napuštanja.

Kad je riječ o karakterizaciji samih posjeta web stranice tad se susrećemo s pojmovima kao što su prethodno spomenuti Landing stranicu, zatim Ulazna stranica koji se odnosi na prvu stranicu posjeta bez obzira na koji način se sesija računa. Važno je razlikovati “Ulaznu“ od Landing stranice, jer je Ulazna stranica obično lista URL-ova ili naziva njihovih stranica dok je Landing stranica prva stranica korisničkog iskustva posjetitelja, a koja rezultira određenom marketinškom aktivnosti. Izlazna stranica je posljednja stranica kojoj je korisnik pristupio tijekom posjeta.

Vrijeme posjeta (Visit Duration) se odnosi na duljinu vremena sesije i važno je da bi se mjerila aktivnost posjetitelja na stranici te zainteresiranost za sadržaj web stranice. Zahtjev za pregled određenog pregleda na stranici može doći iz različitih izvora, tad govorimo o “Referrerima“ (Uputne stranice). To su oni URL-ovi koji su prvi generirali zahtjev za prikazivanje određenog pregleda. Pa tako imamo:

- Unutarnje referere – to je URL koji je sastavni dio stranice kao i pregled stranice za koji je poslan zahtjev za pregled, obično imaju istu domenu.
- Vanjske referere – URL-ovi koji nisu sastavni dio stranice već su vanjske poveznice i uglavnom je domena različita
- Search referrer – može biti unutarnji ili vanjski “referrer“ čiji se URL generira funkcijom pretraživanja

- Visit refferer – prvi posjetitelj unutar sesije bez obzira iz kojeg izvora dolazi
- Originalni referrer – prvi “referrer“ u prvoj posjetiteljevoj sesiji bez obzira otkud on došao

Jedna od važnih metrika za web analitiku je metrika “click-through“. Ona govori koliko puta je posjetitelj kliknuo na link. Obično se veže s marketinškim aktivnostima, bilo vanjskim ili unutarnjim. Ipak, kod marketinških mjerenja još je važnija metrika click-through rate (CTR) koja govori koliko puta je neki link kliknut u odnosu na broj njegovih prikaza. U slučaju niskog CTR-a kod oglasa, to može biti signal da oglasi ne komuniciraju pravu poruku ili da sadržaj nije relevantan posjetiteljima kojima se sadržaj komunicira. Metrika “Page views per visit“ (Pregled stranica po posjetu) se odnosi na broj pregledanih stranica u određenom vremenu podijeljen s brojem posjeta u istom periodu vremena.

Ove metrike i dimenzije možemo grupirati prema kategorijama, pa tako imamo:

- Metrike koje opisuju posjete – odnosi se na dimenzije kao što su Prednja stranica (ulazna stranica), ciljana stranica (landing stranica), izlazna stranica (exit page) i metrike kao što su dužina posjeta (visit duration – time on site), izvor prometa (referrer) i broj klikova na link (click-through rate).
- Metrike za opis posjetitelja – ove metrike predstavljaju različite attribute koji karakteriziraju web posjetitelje te služe kao potpora procesu segmentacije posjetitelja. Pa tako imamo metrike poput novih posjetitelja (new visitors), posjetitelji koji se vraćaju (returning visitors), posjetitelji koji se vraćaju dva ili više puta u određenom vremenskom razdoblju (repeat visitors), broj posjeta po jednom posjetitelju, vrijeme koje je proteklo od posljednje aktivnosti posjetitelja na stranici (recency) te broj puta u kojima je posjetitelj odradio neku promatranu radnju na stranici (frequency).
- Metrike koje opisuju posjetiteljevu uključenost – ove metrike zapravo opisuju stupanj interakcije posjetitelja sa sadržajem na web stranici. Metrike koje ova kategorija sadrži su: omjer onih koji napuste stranicu, a da su imali nekakvu interakciju sa sadržajem nasuprot ukupnom broju pregleda stranice (page exit



ratio), stopa odustajanja (bounce rate), broj pregledanih stranica po posjetitelju (page views per visitor).

- Konverzijske metrike – kolekcije specijalnih web aktivnosti koje pružaju poslovnu vrijednost kao npr. broj uspješno ostvarenih zadanih ciljeva (conversions), omjer između broja ostvarenih konverzija i ostalih relevantnih metrika (conversion rate).

Ove metrike su vrlo često i ključni pokazatelji performansi tzv. KPI za poduzeća. Dakako, izbor metrika koje će se pratiti ovisi o poduzeću i njegovim ciljevima te će se vrlo često razlikovati. Ipak, neke najčešće KPI-je možemo grupirati u nekoliko poslovnih modela<sup>25</sup>:

- Komercijalni model – omjer novih posjetitelja i onih koji se vraćaju, postotak novih posjeta, uputne domene, ključne riječi i fraze pretraživanja, prosječna vrijednost narudžbe, stopa ključnih konverzija.
- Oglašavajući model – ukupan volumen prometa, broj posjeta, omjer novih posjetitelja i onih koji se vraćaju, postotak novih posjetitelja, uputne domene, prosječan broj posjeta po jednom posjetitelju, prosječno vrijeme provedeno na stranici.
- Model pretplate – ukupan volumen prometa, postotak novih posjetitelja, omjer novih posjetitelja i onih koji se vraćaju, uputne domene, ključne riječi i fraze pretraživanja, stopa ključnih konverzija.
- Model korisnosti – ukupan volumen prometa, postotak novih posjetitelja, uputne domene.
- Model informacijskog agenta – omjer novih posjetitelja i onih koji se vraćaju, postotak novih posjetitelja, uputne domene, ukupan volumen prometa, prosječan broj pregledanih stranica po jednom posjetitelju.
- Model manufakture – ključne riječi i fraze pretraživanja, ulazne stranice, uputne domene, stopa ključnih konverzija, broj posjeta.

---

<sup>25</sup> Peterson E.T. (2004.): Web Analytics Demystified: A Marketer's Guide to Understanding How Your Web Site Affects Your Business. Celilo Group Media and CafePress, Portland, Oregon.

- Model podružnice – ukupan volumen prometa, uputne domene, prosječno vrijeme provedeno na stranici.
- Brokerage model – broj posjetitelja koji se vraćaju, učestalost posjeta, broj posjeta, ključne riječi i fraze pretraživanja.

### 1.3.3. Alati za web analitiku

S obzirom da je web analitika postala vrlo važan segment online poslovanja, posljednjih godina se razvio velik broj alata za web analitiku.

Jedna od osnovnih podjela je naravno ona koja je vezana uz plaćanje. Dakle, razlikujemo alate koji se plaćaju i koji su besplatni. S obzirom da postoji nekoliko alata poput Google Analyticsa, koji je ujedno i najpoznatiji alat za web analitiku, postavlja se pitanje je li se uopće isplati ulagati, odnosno plaćati alate za web analitiku. Većina stručnjaka smatra da manja poduzeća i oni koji su početnici u korištenju web analitike bi se trebala držati besplatnih opcija jer im pružaju sasvim dovoljno podataka za vještine kojima oni raspolažu. Onda nakon što razviju svoje analitičke vještine mogu uložiti novac u plaćene alate koji će im dati još dublje uvide u podatke.

Osim ovakve podjele koja je vezana isključivo uz financijski aspekt, alate za web analitiku još možemo podijeliti na slijedećih nekoliko kategorija<sup>26</sup>:

- Tradicionalni alati za web analitiku koji se uglavnom oslanjaju na “clickstream“ (tok klikova) podatke prikupljene od posjetitelja, konkurencije ili iz unutarnjih izvora poduzeća
- Alati za web analitiku koji prate performanse na društvenim mrežama
- Alati koji prikupljaju povratne informacije od posjetitelja, oni imaju za cilj dobiti odgovore na pitanja o razlozima zbog kojih se posjetitelji ponašaju na određeni način
- Alati za web analitiku stranica koje su optimizirane za mobilne uređaje. Pojavom smartphone uređaja korištenje mobilnog interneta je drastično poraslo te je shodno tome i web analitika za mobilne web stranice postala iznimno važna.

---

<sup>26</sup> Texeira, J. (2011.): Get Involved: 5 types of web analytics tools to start using today. Preuzeto: [16.02.2017.]

- Alati za testiranje, eksperimentiranje i pronalaženje optimalnih tehničkih ili dizajn rješenja koje bi povećale zadovoljstvo korisnika.

Tradicionalni alati za web metriku mogu postojati kao software instaliran na organizacijskim računalima ili kao usluga od strane ponuđača aplikacijskih usluga. Dakle mogu postojati kao tzv. otvoreni ili komercijalni paketi. Kao takvi, imaju različite prednosti i nedostatke<sup>27</sup>:

Tablica 1. Alati za web analitiku

	Alat za web analitiku	Prednosti	Nedostatci
Web log alati	Google Analytics	Prilagodljivi dashboardi, vizualizacija konverzija, izvoz podataka u različitim formatima, napredna segmentacija	-
	Webtrend Analytics	Pruža detaljne informacije, izvrsne toplinske mape, pristup podacima u stvarnom vremenu	Visoka cijena
	FireStats	Jednostavan za korištenje, podaci u stvarnom vremenu	Ne preporuča se početnicima radi kompliciranih zahtjeva pri instalaciji
	AWStats	Otkriva koliko vremena posjetitelji potroše na stranici, procesira sirove log podatke, otvoren pristup	Nije moguće provesti dubinsku analizu, nije moguće mjeriti aktivnost korisnika
	Webalizer	Osvježava log podatke tokom	Ne koristi kolačiće, moguće

<sup>27</sup> Bekavac I., Praničević D. G. (2015): Web analytics tools and web metrics tools: An overview and comparative analysis, Croatian Operational Research Review, Split

		dana, jednostavno je razumjeti izvještaje	je precjenjivanje podataka
	StatCounter	Pristup podacima u realnom vremenu, omogućuje analizu na dvije razine	Zastarjelo korisničko sučelje
	Mint	Prilagodljiv, intuitivno sučelje	Potrebna konfiguracija servera
Page tagging alati	Piwik	Prilagodljiv, kontrola podataka, izvještaji o prometu u realnom vremenu, segmentacija	-
	Clicky	Podaci u stvarnom vremenu, toplinske mape, odvojeno testiranje i A/B testiranje	Neintuitivno sučelje
	Chartbeat	Podaci u stvarnom vremenu, user-friendly sučelje	Nema detaljnih povijesnih podataka
	GoSquared	Otkriva koliko dugo se korisnik zadržao na stranici	Mjesečni limit na pregled stranice
	FoxMetrics	Prati evente kao newsletter preglede	Ključne značajke su dostupne u premium verziji
	GoingUp	Uključuje alate vezane za SEO, toplinske mape mape	-
	eTracker	Prati kretanje miša posjetitelja, mogućnost provođenja upitnika	Visoka cijena
	IBM Unica NetInsight	Fleksibilni i prilagodljivi izvještaji, prilagodljivi dashboardi	Visoka cijena
	Stuffed Tracker	Omogućuje usporedbu organskog i plaćenog prometa	Zahtjevna instalacija
	Crazy Egg	Jako dobra toplinska mapa	-

Pri odabiru alata za web analitiku najvažnije je da poduzeće u obzir uzme karakteristike svoje organizacije. Dakle, važno je da se u obzir uzme korisnost, funkcionalnost, tehnički detalji te ukupan trošak alata. Vrlo je važno razmotriti i značajke poput mogućnosti instaliranja i korištenja softwera lokalno, zatim korisničke podrške, ukupnih troškova, mogućnosti segmentacije podataka, mogućnosti downloada programa, vlasništva nad prikupljenim podacima te mogućnosti integracije podataka iz drugih izvora.

#### **1.3.4. Google Analytics**

Google-ov alat koji je u marketinškom svijetu zauzeo mjesto broj jedan kad su u pitanju alati za praćenje prometa na web mjestu. Google Analytics omogućava vlasnicima web mjesta praćenje i izvještavanje o prometu na web mjestu, dakle kompletan uvid u statistiku posjeta web mjestu od strane korisnika, odnosno posjetitelja. Alat je pušten na tržište u studenom 2005. godine nakon što je Google napravio akviziciju alata Urchin na osnovu kojeg je napravljen Google Analytics. Kao što je prethodno spomenuto, Google Analytics je od tada postao najkorištenija usluga za web analitiku na internetu. Iako je poznat kao besplatan alat, GA ima i inačicu koja se plaća, a korisnicima pruža dublje uvide i izvještaje o prometu na web mjestu, njezin naziv je Google Analytics 360. Također, postoji i verzija GA koja se koristi za prikupljanje podataka s iOS i Android aplikacija, a njezin naziv je Google Analytics for Mobile Apps.

GA pruža širok spektar mogućnosti kad se radi o uvidu u promet na web mjestu. Osim praćenja standardnih metrika, kao što su posjete, pojedini posjetitelj, pregled stranice, bounce rate, stopa napuštanja i slično, moguće je pratiti ishod poslovanja, tzv. goals ili ciljeve<sup>28</sup>. Jedan od razloga zbog kojih je GA toliko popularan je i činjenica da može pratiti različite vrste marketinških aktivnosti, a ne samo Google AdWords kako većina ljudi misli. Pa tako može pratiti različite vrste plaćenog oglašavanja na tražilicama, e-mail marketing, oglašavanje

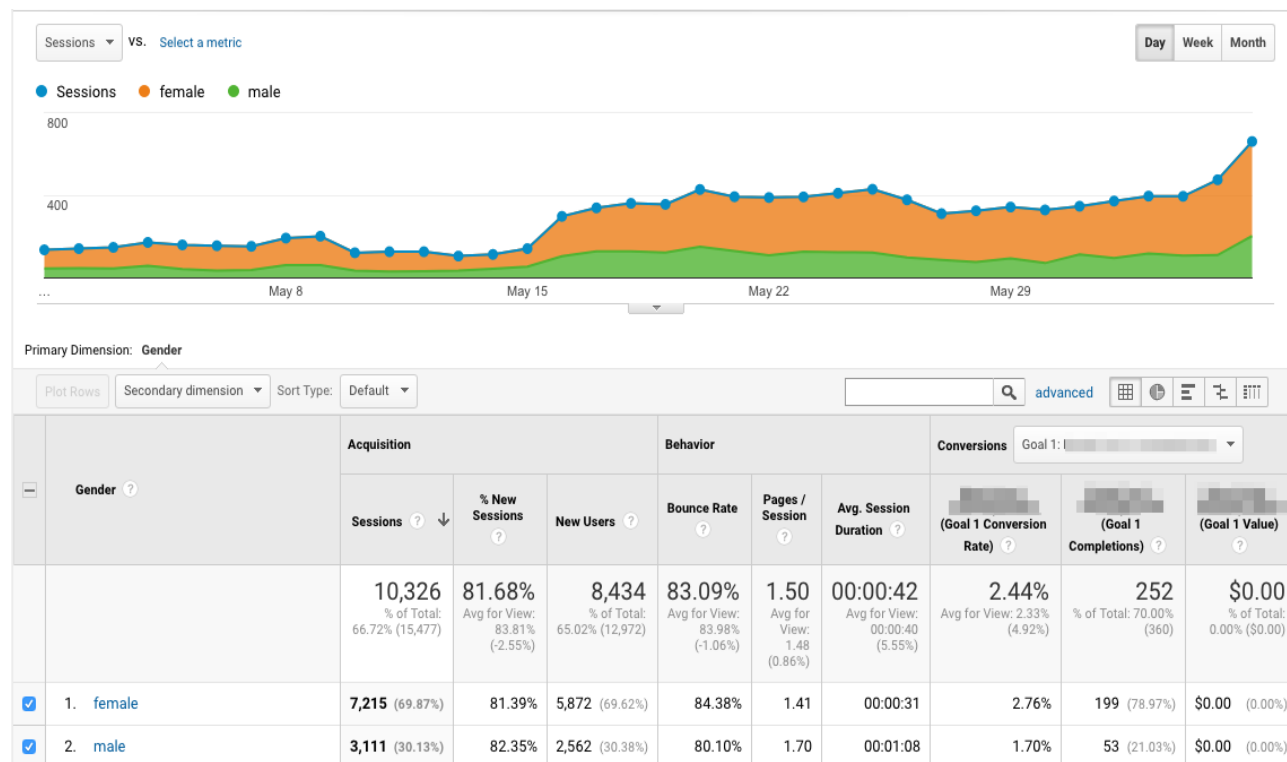
---

<sup>28</sup> Cutroni, J. (2010.): Google Analytics, O'Riley Media, str. 4

na display mrežama, oglašavanje na društvenim mrežama te slične vrste oglašavanja na različitim platformama, mrežama i tražilicama.

Jedna od ključnih aktivnosti koju svi analitičari koriste i koja je od velike važnosti je segmentacija. Segmentacija pruža dublji uvid u podatke o prometu na web mjestu te je važna da bi analitičar dobio uvid u rezultate određenih segmenata prometa te utvrdio kakav utjecaj oni imaju na cjelokupne rezultate web mjesta. Primjer jednostavne segmentacije bi bio pregled prometa na web mjestu prema spolu korisnika. Analitičar može utvrditi koji spol češće posjećuje web mjesto te prema tome dati prijedlog za prilagodbu sadržaja na web mjestu.

Slika 3. Segmentacija prometa po spolu



Izvor: analytics.google.com

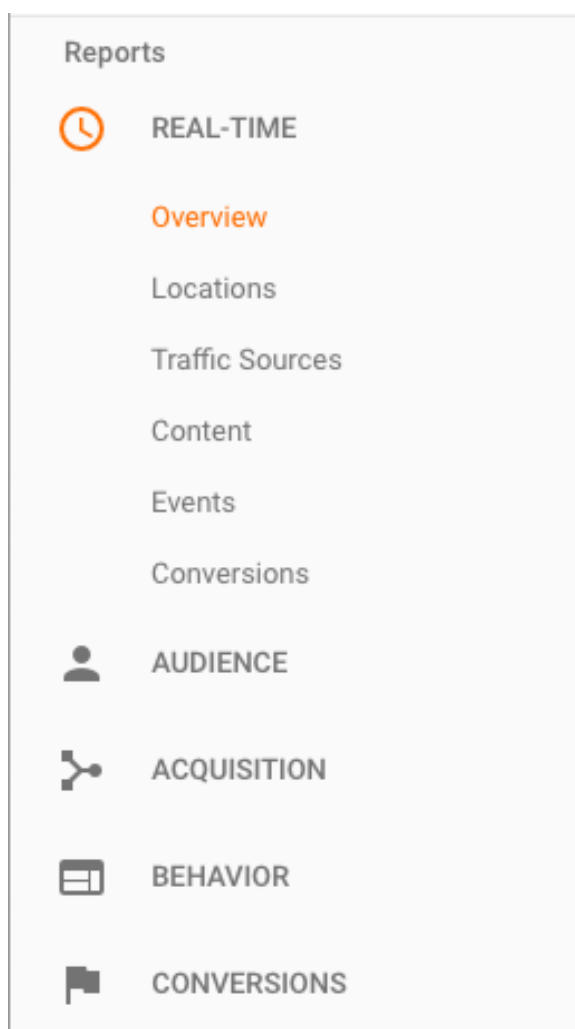
Na primjeru sa slike se može uočiti da skoro 70% posjeta u promatranom razdoblju se odnosilo na osobe ženskog spola. Iako, može se primijetiti da se muškarci u prosjeku zadržavaju dosta dulje na stranicama od žena (Prosječno trajanje sesije = 00:01:08) te da u prosjeku pregledaju više stranica (Stranice/Sesije = 1.70) od osoba ženskog spola, ali ono što

je vlasniku web mjesta uglavnom najvažnije jest činjenica da žene u prosjeku imaju veću stopu konverzije od muškaraca (Stopa konverzije = 2.76%). Na osnovu ove jednostavne analize može se zaključiti da je relevantnija ženska publika, ali je važno uočiti da se kratko zadržavaju na web stranicama te da imaju visoka stopa napuštanja što znači da bi vlasnik web mjesta trebao razmisliti o prilagodbi web sadržaja ženskoj publici te da na taj način još više poveća stopu konverzije i dulje zadrži ciljanu publiku na web stranicama.

### 1.3.5. Izvještaji u Google Analyticsu

GA nam pruža različite mogućnosti uvida u promet na web mjestu.

Slika 4. Izbornik s izvještajima u Google Analyticsu



Google Analytics nam nudi širok spektar mogućnosti kad govorimo o izvještavanju. Real-time izvještaji daju podatke o korisnicima koji se u stvarnom vremenu nalaze na web mjestu. Pa nam tako pruža uvid s koje geografske lokacije korisnik dolazi, zatim koji je izvor prometa s kojeg dolazi, je li se radi o direktnom dolasku na web mjesto, dolasku preko organskih rezultata, plaćenog prometa ili nekih uputnih stranica. Zatim možemo saznati koje sadržaje pregledava pomoću URL adresa koje posjećuje. Naposljetku, možemo još i saznati je li posjetitelj odradio neki event koji smo postavili te je li u konačnici konvertirao.

Osim analize u stvarnom vremenu koja nam daje informacije o posjetima u realnom vremenu, a koja je ipak nešto “siromašnija” podacima, Analytics na pomoću slijedeće četiri kategorije izvještaja daje potpuni uvid u praćenje i mjerenje posjetitelja, izvora prometa, ciljeva, konverzija i ostalih metrika koje su nam važne, stoga generira izvještaje važne za<sup>29</sup>:

- Analizu publike
- Analizu akvizicija
- Analizu ponašanja
- Analizu konverzija

Analiza publike, kao što joj i samo ime govori daje detaljan uvid u publiku koja posjećuje web stranice, skupa s povijesti njihovih sesija, pregleda stranice, stopa napuštanja, prosječno provedenog vremena na stranici i sl. Ovi izvještaji omogućuju praćenje, kako novih tako i onih posjetitelja koji se vraćaju na web mjesto nakon što su ga već prethodno posjećivali. Analiza publike omogućava praćenje:

- Spola i godina posjetitelja pod Demographics
- Preferencije posjetitelja i segmentaciju tržišta pod Interests
- Jezik i lokaciju pod Geo

---

<sup>29</sup> Tutorials Point (2015.): Web analytics, e-book, str. 3



- Nove posjetitelje, one koji se vraćaju te učestalost njihovih posjeta i interakciju sa sadržajem pod Behaviour
- Tražilice, operacijske sisteme i mrežu preko koje posjetitelj dolazi pod Technology
- Informacije o mobilnim uređajima pod Mobile
- Izvještaj o prilagođenim varijablama pod Custom
- Benchmarking kanale, uređaje i lokacije pod sekcijom Benchmarking. Benchmarking nam omogućuje usporedbu naših metrika s ostalim povezanim industrijama
- Tok aktivnosti korisnika pod sekcijom Users flow omogućava praćenje puta posjetitelja na stranici

Analiza akvizicija se provodi zato da bi saznali iz kojih izvora se generira promet na web stranici. Korištenjem analize akvizicija je moguće:

- “Uхватiti” promet sa svih izvora, posebice izvor/medij te referral izvora
- Pratiti promet s AdWords kampanja (plaćeni promet)
- Uvid u promet s tražilica, vidjeti pojmove koje korisnici pretražuju, landing stranice na koje su došli te podatke prema geografskoj lokaciji posjetitelja
- Pratiti promet s društvenih mreža. To pomaže pri identifikaciji onih mreža na kojima korisnici imaju bolju interakciju sa sadržajem. Također, moguće je vidjeti i referral stranice s kojih promet dolazi na stranicu.
- Vidjeti koji plug-in dovodi promet
- Pregled svih kampanja koje su izgrađene preko web stranice s detaljnim statistikama plaćenih ili organskih ključnih riječi i cjelokupnim ulaganjima u njih

Analiza ponašanja prati aktivnosti posjetitelja na web stranici. Podatke o ponašanju posjetitelja na stranici je moguće naći pod sljedeća četiri segmenta:

- Sadržaj stranice – daje podatke o tome koliko je stranica pregledano. Moguće je vidjeti detaljnu interakciju podataka preko svih stranica ili segmenata kao što je drill-down (razlaganje) sadržaja, landing stranice te stranice izlaska. Drill-down sadržaja je razlaganje podataka u pod-foldere. Landing stranice su one stranice na koje posjetitelj slijeće, a izlazne stranice su one stranice koje posjetitelj posljednje posjeti prije nego

što napusti web mjesto. Također, moguće je pratiti i tijek ponašanja kad se radi o pregledu sadržaja.

- Brzina stranica – moguće je pratiti vrijeme učitavanja stranice, brzinu izvršavanja te performanse podataka. Moguće je vidjeti i koliko brzo browser analizira stranicu te dobiti savjete o poboljšanju brzine stranice kao i saznati koji dijelovi stranice su sporni.
- Pretraga stranice – daje cjelokupnu sliku načina na koji korisnici pretražuju sadržaje na stranici, što najčešće traže te na koji način dolaze na određenu landing stranicu. Moguće je analizirati što točno pretražuju prije nego slete na landing stranicu.
- Događaji – su akcije posjetitelja sa sadržajem stranice, a mogu se pratiti pojedinačno. Primjer takvih akcija su download, prijava, log-in i sl.

Analiza konverzija – konverzija je ispunjenje cilja ili transakcija od strane posjetitelja web mjesta. Kupnja, download, prijava na newsletter i sl. akcije su neki od primjera konverzije. Da bi se konverzije mogle pratiti u Analyticsu, važno je definirati ciljeve i postaviti URL koji se može pratiti.

- Ciljevi su metrika koja mjeri profitabilne aktivnosti koje je poželjno da posjetitelj napravi na stranici. Moguće ih je postaviti tako da se prate akcije. Svaki put kad se neki od postavljenih ciljeva ostvari, zabilježi se konverzija u podacima. Moguće je pratiti ostvarenje cilja, vrijednost, obrnuti put ostvarivanja cilja i tok ostvarivanja cilja.
- E-commerce je moguće postaviti na stranicu kako bi znali što posjetitelji kupuju na stranici. Pomaže da vlasnik web mjesta sazna koji proizvodi se najbolje prodaju, kakvi su rezultati prodaje, informacije o transakcijama te koje je vrijeme ostvarenih prodaja. Na osnovu podataka iz e-commercea moguće je analizirati što donosi profit, a gdje se ne ostvaruju željeni povrati, odnosno gubitak.
- Multi-kanalni lijevak ili MCF izvještava o izvoru konverzije, koju ulogu je web stranica odigrala u procesu konverzije, koja je uloga uputnih stranica i sl. Npr. kad korisnik pretražuje pojam i na taj način dođe na landing stranicu i ne napravi konverziju već sljedeći put dođe na stranicu izravnim upisivanjem adrese u browseru i tad napravi konverziju. Ovakav način praćenja je moguć putem MCF izvještavanja.

- Atribucija omogućava informacije koje pomažu shvatiti koja je platforma, strategija ili modul najbolja za poslovanje. Npr. ako neka osoba dođe na landing stranicu preko AdWords oglasa i ne ostvari kupnju, pa zatim nakon mjesec dana dođe preko društvenih mreža na stranicu i opet ne napravi kupnju već tek sljedeći put, kad dođe direktnim upisivanjem adrese, izvrši kupnju. U tom slučaju model posljednje interakcije će sugerirati da je Direkt promet zaslužan za ostvarenu kupnju, dok će model prve interakcije zasluge pripisati AdWords oglasu. Na ovaj način se može analizirati koji je modul zaslužan za određenu konverziju.

## **2. Empirijsko istraživanje**

Empirijsko istraživanje je podijeljen na dva dijela. Prvi dio se odnosi na analizu performansi postojećeg web mjesta pomoću rezultata iz Google Analyticsa.

Cilj prvog dijela istraživanja je ustanoviti funkcionalnost, profitabilnost, iskustvo korisnika te poziciju web mjesta na tržištu vodeći se trenutnim standardima tržišta. Za ovaj dio istraživanja će se koristiti podaci iz Google Analyticsa.

Drugi dio istraživanja će se fokusirati na rudarenje web stranica konkurentskih poduzeća kako bi zaključili koje sve elemente web mjesto mora imati kako bi bilo profitabilno i poticalo posjetitelje na ostvarivanje konverzija.

### **4.1. Analiza rezultata postojeće web stranice poduzeća Colosseum**

#### **4.1.1. O poduzeću Colosseum**

Društvo Colosseum d.d. ima sjedište na otoku Hvaru, poduzeće je s 25 godina tradicije u turizmu kao osnovnoj djelatnosti, a bavi se pružanjem usluga smještaja i ostalih ugostiteljskih

usluga karakterističnih za djelatnost hotelskih poduzeća. Od samog početka rada poduzeća postavljani su visoki ciljevi kad se tiče pozicioniranja poduzeća na tržištu. Cilj poduzeća je postati jedan od najpoznatijih hotelskih brendova na Jadranu. Colosseum hoteli d.d. je u javnosti percipirana kao moderna, inovativna, vrlo dobro organizirana te jedna od vodećih poduzeća u domeni hotelijerstva u Republici Hrvatskoj.

Colosseum d.d. u svojem vlasništvu ima 12 hotela s ukupno 9 620 jedinica smještaja. Hoteli koji posluju u sastavu društva su prepoznati kao visokokvalitetni pružatelji smještaja kako u zemlji tako i u inozemstvu. Hoteli u sastavu društva su od svog otvaranja imali iznimno važnu ulogu kako za lokalnu zajednicu tako i na nacionalnoj razini.

Politika razvoja hotela je usmjerena k sustavnom unaprjeđenju kvalitete usluga smještaja u skladu s vizijom Ministarstva turizma Republike Hrvatske, a s ciljem pretvaranja odredišta u prestižno turističko odredište. Pa tako u skladu s navedenim, politika ulaganja teži pozicioniranju svih hotelskih objekata na kategorije 4 i 5 zvjezdica, a filozofija ulaganja temelji se na poštivanju regionalnih vizualnih obilježja te valoriziranju osobnosti svakog objekta. Ovisno o razini dostignute kategorije, u objektima se implementiraju visoki međunarodni standardi ugostiteljskih usluga, kontinuirano se provode programi edukacije, kao i aktivnosti usmjerene motivaciji i podizanju razine zadovoljstva zaposlenika.

Uprava poduzeća se obvezala da će svi hoteli unutar društva poslovati prema odrednicama održivog razvoja u svim segmentima djelovanja, krenuvši od zaštite prirodnog okoliša do podržavanja lokalne kulture i izgradnje kvalitetnih odnosa s lokalnom zajednicom. Kad se govori o operativnom poslovanju, menadžment se zalaže za efikasnost, učinkovitost i ekonomičnost u cilju ostvarenja interesa vlasnika i dioničara.

#### **4.1.2. Vizija i misija poduzeća**

Vizija<sup>30</sup> društva Colosseum d.d. je da pomoću tržišnog repozicioniranja, moderniziranja poslovanja i sustavnog unaprjeđivanja na svim razinama poslovanja pomoću podataka

---

<sup>30</sup> Vizija društva je preuzeta s web stranice poduzeća. Preuzeto: [12.02.2017.]

prikupljenih iz unutarnje i vanjske okoline poduzeća, pozicionira društvo kao tržišnog lidera u domeni turističkog poslovanja na Jadranu.

Osim osnovnog cilja koji je usmjeren na zauzimanje liderske pozicije na tržištu, vlasnička očekivanja usmjerena su i prema ostvarenju financijskih rezultata adekvatnih tržišnom potencijalu, a u skladu s međunarodnim standardima hotelske industrije.

Misija<sup>31</sup> društva Colosseum d.d. je postati visokokvalitetno i prepoznatljivo turističko poduzeće na jadranskoj obali uz ponudu autentične hrvatske atmosfere, visoko personalizirane i gostoljubive usluge kao i razvijanje modernih, konkurentnih sadržaja koji će gostima hotela omogućiti istinske doživljaje u cilju zadovoljenja potreba svih gostiju.

#### **4.1.3. Strategija razvoja poduzeća**

Uprava poduzeća je donijela strateški plan razvoja<sup>32</sup>, a njegove najvažnije odrednice su sljedeće:

- Izgradnja konkurentske pozicije i stvaranje prednosti na međunarodnom tržištu nudeći suvremenu i kvalitetnu hotelsku uslugu uklopljenu u destinaciju u kojoj objekti egzistiraju.
- Aktivna suradnja s javnim sektorom pri implementaciji razvojnog plana regije u kojoj se nalaze ugostiteljski objekti tvrtke.
- Poticati institucije javnog sektora na provođenje aktivnosti kvalitetnijeg pozicioniranja domaćih turističkih destinacija na stranim tržištima.
- Politiku ulaganja usmjeriti podizanju kategorije vlastitih objekata na razinu 4 i 5 zvjezdica.
- Filozofiju ulaganja zasnivati na poštivanju vizualnih obilježja regionalnog identiteta i valoriziranju osobnosti svakog objekta.

---

<sup>31</sup> Misija društva je preuzeta s web stranice poduzeća. Preuzeto: [12.02.2017.]

<sup>32</sup> Interni dokument; Strategija razvoja Colosseum d.d. (2015.-2018.)

- Razvijati nove oblike turističke ponude i usluga usmjerenih gostima, njihovim aktivnostima te emocionalnim doživljajima u cilju produljenja i intenziviranja turističke sezone.
- Razmišljati i djelovati ekološki, valorizirati i čuvati prirodne resurse, lokalnu kulturu te vlastitim primjerom djelovati na razvoj ekološke svijesti lokalne zajednice.
- Kontinuirano ugrađivati najviše međunarodne standarde hotelsko-ugostiteljskih usluga.
- Ulagati u edukaciju i standard zaposlenika i ponašati se u skladu s dobrom praksom socijalne odgovornosti.

#### **4.1.4. Poslovni ciljevi poduzeća**

Na temelju strategije razvoja poduzeća, čije se glavne odrednice prikazane u prethodnom odjeljku, menadžment poduzeća Colosseum d.d. definirao je sljedeće strateške poslovne ciljeve:

- Pozicioniranje tvrtke – pozicioniranje na mjesto lidera u hotelskoj industriji na Jadranu. Ovaj cilj se nastoji ostvariti putem kreiranja brenda pružatelja turističkih usluga najviše razine kvalitete.
- Tržišna pozicija – stvaranje prepoznatljivih brendova na domaćem i stranom tržištu i jačanje konkurentske pozicije kroz povećanje prihoda po raspoloživoj jedinici.
- Resursi – osiguranje diverzificiranih vještina zaposlenika te modernih tehnologija koje mogu primjereno podržavati poziciju tržišnog lidera.
- Kadrovi – izgradnja stručnih kadrova koji su nosioci suvremenih menadžerskih sposobnosti te su jako dobri poznavatelji trenutnog stanja i aktualnih trendova u turizmu.

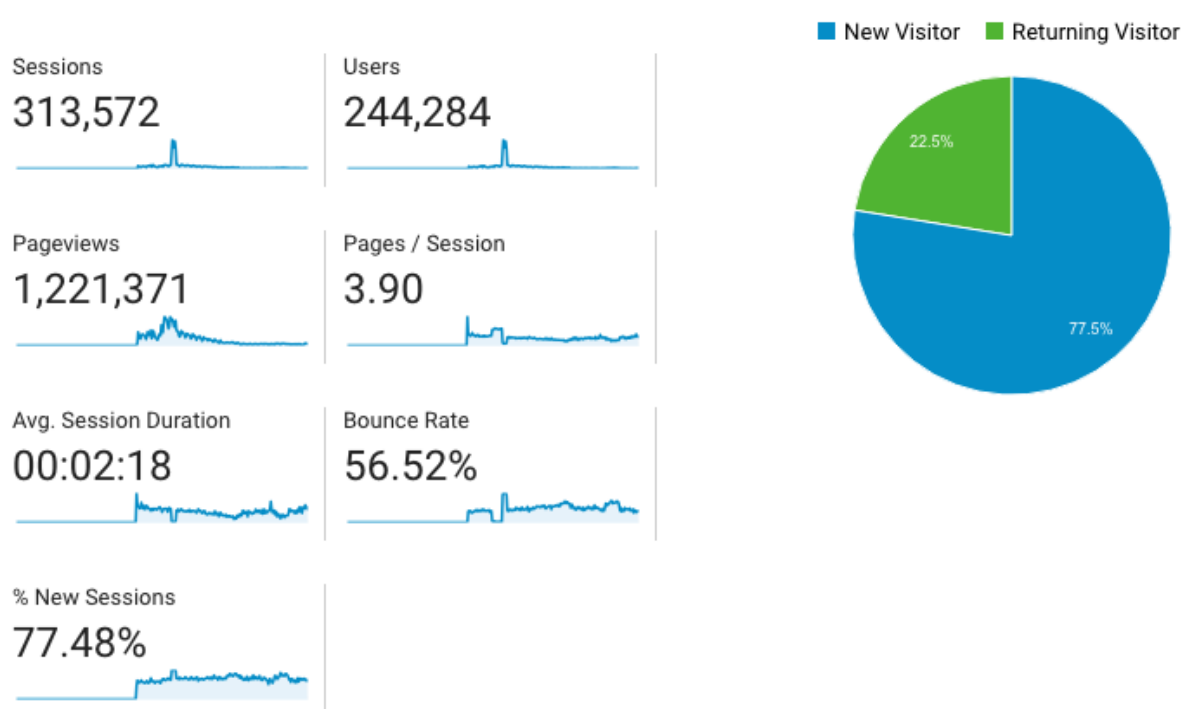
#### **4.2. Trenutno stanje i rezultati web stranice**

Trenutna web stranica postoji dugi niz godina i ima isključivo informativni karakter. Prema modernim standardima dizajn i tehnologija izrade web stranice se smatraju zastarjelima.

Stranica ne sadrži rezervacijski sustav te osim kontakt podataka (telefonski broj i e-mail adresa) ne postoji nikakav oblik komunikacije kojim bi posjetitelji mogli rezervirati smještaj. S obzirom na karakter stranice, sve promotivne aktivnosti, poput plaćenog oglašavanja, su se provodile isključivo radi izgradnje prepoznatljivosti brenda, a ne prodajnih aktivnosti.

Podaci s web stranice se prate pomoću Google Analyticsa u razdoblju od 01.01. do 31.12. u prethodnoj poslovnoj godini<sup>33</sup>. Svi podaci su sumirani za cjelokupno vremensko razdoblje, odnosno za svih dvanaest mjeseci zajedno.

Slika 5. Distribucija posjetitelja poduzeća Colosseum d.d.



Izvor: analytics.google.com

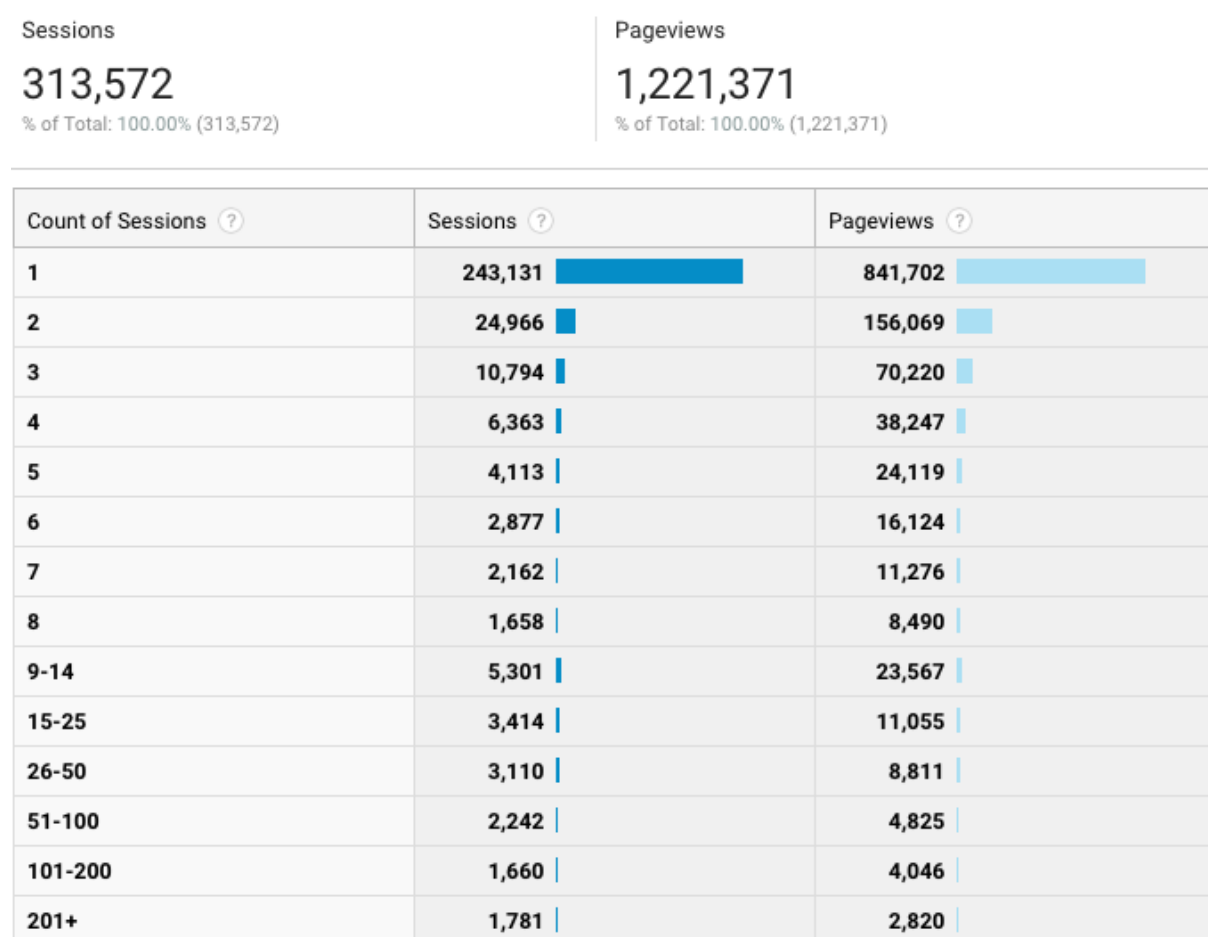
U promatranom razdoblju je ostvareno 313,572 sesije od strane 244,284 korisnika. Broj korisnika se ne odnosi na jedinstvene posjete već se u taj broj ubrajaju i posjetitelji koji su se vraćali na stranicu. Možemo vidjeti iz grafa da je od ukupnog broja posjetitelja 22,5% njih koji su se ponovno vraćali na stranicu dok je 77,5% novih posjetitelja. S obzirom na dizajn

<sup>33</sup> Svi podaci su prikupljeni s Google Analytics računa poduzeća Colosseum d.d.

stranice, ostvaren je solidan rezultat kad je riječ o broju stranica po sesiji (3.90) i stopa napuštanja (56.52%). Ovi rezultati upućuju na to da posjetitelji pokazuju interes za sadržajem na stranicama.

Na slici broj 6. je prikazana distribucija posjetitelja prema frekvenciji i učestalosti. Na slici možemo uočiti kako izrazito velik broj sesija opada na jednu sesiju po posjetu, čak njih 243,131. Isto tako je i većina pregleda stranice napravljena unutar jedne sesije po posjetu. Iako je prirodno da, unatoč kvaliteti web stranice, najveći broj sesija opada na jednu sesiju po posjetu, u ovom slučaju je taj broj prevelik i sugerira da na stranici postoji određeni problem sa sadržajem. Velika većina posjetitelja napusti web stranicu nakon samo jedne sesije i to sugerira da postoji nekakav problem sa sadržajem s obzirom da se posjetitelji ne zadržavaju na web stranici dugo.

Slika 6. Frekvencija i učestalost posjeta





Izvor: analytics.google.com

Kad je riječ o izvorima prometa, iz statistike na slici broj 7. možemo vidjeti da najveći broj posjetitelja došao direktnim upisivanjem adrese u tražilicu te putem organskih rezultata pretraživanja. Mnogo je manji broj posjetitelja, odnosno mnogo manji broj sesija je ostvaren putem plaćenog oglašavanja. Razlog zbog kojeg je broj posjetitelja koji su došli preko plaćenog oglašavanja dosta manji od organskog i direktnog prometa je taj što su sve marketinške aktivnosti bile usmjerene samo ka izgradnji svijesti posjetitelja o brendu. S obzirom da na stranici ne postoji rezervacijski sustav ili bilo kakav drugi oblik izravne komunikacije na web stranici preko kojeg bi posjetitelj mogao rezervirati smještaj, može se zaključiti da poduzeće na tom planu može napraviti veliki iskorak pri izgradnji nove web stranice i okrenuti se akviziciji prometa preko plaćenog oglašavanja na internetu.











Slika 7. Distribucija prometa prema izvorima

Source / Medium ?	Acquisition			Behavior		
	Sessions ? ↓	% New Sessions ?	New Users ?	Bounce Rate ?	Pages / Session ?	Avg. Session Duration ?
	<b>313,572</b> % of Total: 100.00% (313,572)	<b>77.54%</b> Avg for View: 77.48% (0.08%)	<b>243,131</b> % of Total: 100.08% (242,946)	<b>56.52%</b> Avg for View: 56.52% (0.00%)	<b>3.90</b> Avg for View: 3.90 (0.00%)	<b>00:02:18</b> Avg for View: 00:02:18 (0.00%)
1. (direct) / (none)	<b>112,878</b> (36.00%)	85.24%	<b>96,217</b> (39.57%)	80.45%	2.11	00:01:00
2. google / organic	<b>88,815</b> (28.32%)	60.45%	<b>53,685</b> (22.08%)	34.41%	6.17	00:04:02
3. google / cpc	<b>50,059</b> (15.96%)	89.66%	<b>44,883</b> (18.46%)	63.15%	3.03	00:01:25
4. [redacted] / referral	<b>14,442</b> (4.61%)	82.25%	<b>11,879</b> (4.89%)	26.40%	4.74	00:02:51
5. hotelrooms.com / referral	<b>5,237</b> (1.67%)	96.16%	<b>5,036</b> (2.07%)	42.89%	2.42	00:01:08
6. [redacted] / referral	<b>5,110</b> (1.63%)	82.45%	<b>4,213</b> (1.73%)	45.48%	4.44	00:02:49
7. facebook.com / referral	<b>2,502</b> (0.80%)	73.14%	<b>1,830</b> (0.75%)	55.64%	3.36	00:02:14
8. [redacted] / referral	<b>2,056</b> (0.66%)	73.98%	<b>1,521</b> (0.63%)	34.97%	5.84	00:03:44
9. bing / organic	<b>1,722</b> (0.55%)	62.25%	<b>1,072</b> (0.44%)	29.85%	6.55	00:04:02
10. budget. [redacted] / referral	<b>1,219</b> (0.39%)	65.55%	<b>799</b> (0.33%)	40.36%	5.09	00:03:55

Izvor: analytics.google.com

Osim direktnih, organskih i cpc izvora prometa možemo primijetiti da manji dio prometa dolazi i s uputnih stranica. Možemo vidjeti da je izvor prometa s Facebook vrlo malen te na tom području postoji mnogo prostora na napredak. Aktivnosti poduzeća na društvenim mrežama su vrlo slabe te bi se na tom području trebalo poraditi na strategiji i implementaciji strategije oglašavanja.

Slika 8. Distribucija posjetitelja prema lokaciji

Country ?	Acquisition			Behavior		
	Sessions ? ↓	% New Sessions ?	New Users ?	Bounce Rate ?	Pages / Session ?	Avg. Session Duration ?
	313,572 % of Total: 100.00% (313,572)	77.54% Avg for View: 77.48% (0.08%)	243,131 % of Total: 100.08% (242,946)	56.52% Avg for View: 56.52% (0.00%)	3.90 Avg for View: 3.90 (0.00%)	00:02:18 Avg for View: 00:02:18 (0.00%)
1.  Croatia	45,101 (14.38%)	66.64%	30,056 (12.36%)	57.02%	3.44	00:01:59
2.  United Kingdom	43,465 (13.86%)	71.86%	31,235 (12.85%)	51.09%	4.61	00:03:05
3.  United States	26,549 (8.47%)	81.30%	21,584 (8.88%)	54.57%	3.68	00:02:25
4.  Italy	18,912 (6.03%)	84.71%	16,021 (6.59%)	54.84%	4.22	00:02:17
5.  Germany	16,405 (5.23%)	81.33%	13,342 (5.49%)	56.09%	4.28	00:02:10
6.  Czechia	13,269 (4.23%)	45.29%	6,010 (2.47%)	55.59%	3.56	00:02:29
7.  China	11,577 (3.69%)	98.39%	11,391 (4.69%)	79.31%	1.45	00:00:14
8.  France	9,139 (2.91%)	79.03%	7,223 (2.97%)	56.58%	3.93	00:02:12
9.  Serbia	8,948 (2.85%)	88.06%	7,880 (3.24%)	58.63%	4.16	00:02:00
10.  Switzerland	8,303 (2.65%)	80.12%	6,652 (2.74%)	60.66%	4.38	00:02:09

Izvor: analytics.google.com

Gledajući distribuciju posjetitelja prema lokaciji možemo utvrditi da podaci nisu nikako u skladu sa željenima. Razlog tomu je jednostavan, u strukturi gostiju hotela Colosseum d.d. broj domaćih gostiju je vrlo malen i gosti su uglavnom iz Velike Britanije, SAD-a, Njemačke, Italije, Austrije i Francuske. Stoga, možemo zaključiti da velik dio prometa koji dođe na stranicu zapravo samo pretražuje informacije i u konačnici ne konvertira, odnosno ne

rezervira smještaj. Jedan od razloga ovakve situacije je što je web stranica prevedena, osim hrvatskog, samo na engleski jezik. Također, ulaganje u plaćeno oglašavanje na stranim tržištima je bilo neznatno što je također utjecalo na ovakvu distribuciju rezultata.

Isto tako, zanimljiv je i pregled distribucije podataka prema uređajima. Postojeća web stranica nema responzivan dizajn, dakle nije prilagođena mobilnim i tablet uređajima. Takva praksa se prema modernim standardima smatra zastarjelom, posebno u vrijeme kada korištenje smartphone uređaja raste munjevitom brzinom iz mjeseca u mjesec.

Slika 9. Distribucija podataka prema vrsti uređaja

Device Category ?	Acquisition			Behavior		
	Sessions ? ↓	% New Sessions ?	New Users ?	Bounce Rate ?	Pages / Session ?	Avg. Session Duration ?
	<b>315,883</b> % of Total: 100.74% (313,572)	<b>77.56%</b> Avg for View: 77.48% (0.10%)	<b>244,989</b> % of Total: 100.84% (242,946)	<b>56.45%</b> Avg for View: 56.52% (-0.12%)	<b>3.90</b> Avg for View: 3.90 (0.24%)	<b>00:02:18</b> Avg for View: 00:02:18 (0.35%)
1. desktop	<b>304,898</b> (96.52%)	78.11%	<b>238,151</b> (97.21%)	56.12%	3.96	00:02:19
2. mobile	<b>10,985</b> (3.48%)	62.25%	<b>6,838</b> (2.79%)	65.60%	2.41	00:01:49

Izvor: analytics.google.com

Prema podacima sa slike možemo vidjeti koliko nedostatak responzivnog dizajna utječe na promet s mobilnih uređaja. Promet s mobilnih uređaja je neznatan u odnosu na desktop uređaje. Čak su i sve kategorije metrika lošije i to ukazuje na problem s kojim se stranica suočava, a to je gubljenje velikog broja potencijalnih gostiju koje svoje odmore rezerviraju putem mobilnih uređaja. Stručnjaci smatraju da bi ovakav način rezervacije smještaja u bliskoj budućnosti mogao biti dominantan te bi na tom području poduzeće trebalo što prije poduzeti potrebne mjere da ne izgubi korak s konkurencijom.

Analizom podataka s Google Analytics računa hotelskog poduzeća možemo zaključiti da rezultati postojeće web stranice nisu u skladu s vizijom i misijom poduzeća. Radi se o zastarjelom, manjkavom, neintuitivnom, jednodimenzionalnom i nadasve neatraktivnom web

mjestu koje je potrebno restrukturirati iz temelja i prilagoditi prema međunarodnim standardima i trendovima.

Također, poduzeće se suočava sa smanjenjem rasta iz godine u godinu, a uprava smatra da bi taj problem mogla riješiti dizajniranjem i implementacijom novog web mjesta koje će, uz sve ostale moderne standarde, sadržavati i rezervacijski sustav preko kojeg će posjetitelji moći direktno na stranicama hotela rezervirati smještaj. Uz novu web stranicu, uprava je odlučila povećati ulaganja u plaćeno oglašavanje na stranim tržištima s kojih dolazi najveći broj posjetitelja, ali su također odlučili da će se širiti i na nova tržišta. Analiza podataka je ukazala na manjkavosti postojeće web stranice, stoga je odlučeno da će se pristupiti izradi nove web stranice.

#### **4.3. Pristup izradi nove stranice**

Kako je prethodno napisano, uprava je odlučila pristupiti izradi nove web stranice koja će biti u skladu s misijom i vizijom poduzeća. S obzirom da poduzeće posjeduje sve potrebne resurse, donesena je odluka da će se web stranica razviti interno. Kako bi stranica bila što bolja, web administrator je dobio zadatak da rudarenjem web stranica konkurentskih poduzeća prikupi informacije na temelju kojih će se pristupiti izradi nove web stranice.

S obzirom da ne postoji standardizirani alat za rudarenje web stranica koji bi bio prikladan za ovaj zadatak, odlučeno je da će se rudarenje provesti ručnim putem. Rudarenje će se provesti na način da će se pregledati web stranice 20 najpoznatijih hrvatskih hotelskih lanaca ili zasebnih hotela, odnosno hotelskih lanaca ili zasebnih hotela koji imaju bar jedan hotel na području Republike Hrvatske. Osim teritorijalnog uvjeta, važno je i da je objekt kategoriziran s tri ili više zvjezdice. Uvjet o kategorizaciji hotela će biti zanemaren jedino u slučaju da hotelski lanac na istom web mjestu nudi mogućnost rezerviranja hotela s manje, jednako ili više od tri zvjezdice.

Kod pretraživanja se služi s listom koja je skinuta sa stranica Ministarstva turizma Republike Hrvatske.

#### 4.4. Istraživanje

Istraživanje je provedeno na 20 hotelskih poduzeća koji se nalaze na teritoriju Republike Hrvatske, izabranih prema veličini, za koju je kriterij bio broj smještajnih jedinica koji je objavljen na stranicama Ministarstva turizma Republike Hrvatske. Osim toga, kriterij je bio i da hoteli imaju više od tri zvjezdice sukladno kategorizaciji Ministarstva turizma.

Tablica 2. Hoteli na kojima je provedeno istraživanje

Naziv hotela	Broj zvjezdica	Elementi (%)
Hotel Hilton Imperial Dubrovnik	5*	69,44%
Hotel Kempinski Adriatic Istria	5*	88,89%
Hotel Monte Mulini Maistra	5*	83,33%
Hotel Valamar Isabella Miramare	5*	75,00%
Hotel Sunčani Hvar Amfora	4*	75,00%
Hotel Regent Esplanade Zagreb	5*	94,44%
Hotel Sheraton Zagreb	5*	66,67%
Hotel Royal Princess Dubrovnik	5*	58,33%
Hotel Trakošćan	4*	52,78%
Hotel Split	4*	69,44%
Hotel Le Meridien Lav	5*	69,44%
Hotel Falkensteiner Zadar	4*	80,56%
Hotel Melia Coral Istraturist	5*	69,44%
Hotel Berulia Bluesun	5*	63,89%
Hotel Aminess Maestral	4*	75,00%
Hotel Atrium Split	5*	66,67%
Hotel The Westin Zagreb	5*	69,44%
Hotel Remisens Ambasador	5*	52,78%
Hotel Bellevue Lošinj	5*	72,22%
Hotel Rixos Libertas Dubrovnik	5*	63,89%

Izvor: Samostalno istraživanje

Kako je vidljivo iz tablice, svi hoteli su kategorizirani s četiri ili pet zvjezdica. Neki od hotela su dio svjetskih hotelskih lanaca, a dio je u vlasništvu domaćih poslovnih subjekata.

Kod prikupljanja informacija o konkurentskim poduzećima, pretraživani su sljedeći elementi:

- Opći podaci o hotelu – ime hotela, ime lanca kojem hotel pripada, grad i država u kojoj se nalazi
- Kategorija hotel – informacije o kategorizaciji hotela
- Telefon – broj telefona putem kojeg se može kontaktirati hotel
- Telefaks – broj na koji se može komunicirati putem telefaksa
- Elektronička pošta – mail adresa putem koje se može kontaktirati hotel
- Precizna adresa – ulica i poštanski broj hotela
- Karta – Google ili neka druga karta koja prikazuje točnu lokaciju hotela na mapi
- Opis načina dolaženja do hotela – detaljan opis načina na koji se može doći do hotela od nekih važnijih destinacija
- Udaljenost hotela – točna udaljenost hotela od nekih poznatijih mjesta
- Udaljenost destinacije – udaljenost mjesta u kojem se hotel nalazi od nekih drugih destinacija kao što su gradovi
- Vanjske poveznice (linkovi) – linkovi na neke vanjske stranice koje su na neki način povezane s hotelom
- Povijest hotela – osvrt na važne događaje u povijesti hotela

U sljedećoj tablici možemo vidjeti rezultate istraživanja o informacijama o hotelu.

Tablica 3. Zastupljenost elemenata koji daju informacije o hotelu na web stranici

Informacije o hotelu	Hoteli koji imaju navedene elemente (%)
Opći podaci o hotelu	100,00%
Kategorija hotela	40,00%

Telefon	100,00%
Telefaks	25,00%
Elektronička pošta	95,00%
Precizna adresa hotela	100,00%
Karta	90,00%
Opis načina dolazanja do hotela	60,00%
Udaljenost hotela	50,00%
Udaljenost destinacije	45,00%
Vanjske poveznice (linkovi)	100,00%
Povijest hotela	10,00%

Izvor: Samostalno istraživanje

Iz tablice možemo vidjeti da su određeni elementi koji pružaju informacije o hotelu vrlo popularni kod svih hotelskih poduzeća. Pa tako elementi Opći podaci o hotelu, Broj telefona, Precizna adresa hotela i Vanjske poveznice (linkovi) su zastupljeni kod svih hotelskih poduzeća. S obzirom da svi, izuzev vanjskih poveznica, daju osnovne podatke o hotelu taj podatak nije iznenađenje.

Osim ovih, kao dva vrlo popularna elementa su se pokazali Adresa elektroničke pošte i Karte. U moderno doba većina komunikacije između turista i hotela se odvija putem elektroničke pošte pa je vrlo važno da hotel na svojoj stranici ima adresu putem koje ga turist može kontaktirati i saznati dodatne informacije koje možda stranica ne pruža. Karte su postale vrlo popularan, gotovo neizostavan, dio svake web stranice hotelskih poduzeća. S obzirom da gosti dolaze iz drugih zemalja i nisu upoznati s hrvatskim gradovima, karte im omogućavaju lakše snalaženje pri dolasku do hotela. Također, karte im nude i informacije o zanimljivim mjestima u neposrednom okruženju samog hotela.

Opis načina dolazanja do hotela je nešto slabije zastupljen kod hotelskih poduzeća u RH. Poput karti, on omogućava gostima da se lakše snađu, odnosno što lakše dođu do lokacije

hotela. Vrlo često se to odnosi na opis dolaska od aerodroma ili autobusnog kolodvora do hotela s obzirom da većina gostiju dolazi putem takvih oblika transporta. Udaljenost hotela daje informacije gostima o udaljenosti hotela od nekih zanimljivih turističkih znamenitosti ili sadržaja. Ovaj element sadrži 50% web stranica pa možemo zaključiti da od strane ponuđača hotelskog smještaja vlada podijeljeno mišljenje o korisnosti ovakvih informacija. Skoro identično je i mišljenje (45%) kad se radi o Udaljenosti destinacije koja pruža informacije o udaljenosti mjesta u kojem je hotel lociran od nekih daljih destinacija kao što su ostali gradovi, turistički sadržaji i sl. Informacije o kategorizaciji hotela sadrži tek 40% web stranica što je zapravo dosta neobičan podatak s obzirom da se radi o elementu koji je sastavni dio informacija o hotelu.

Elementi koji su najmanje zastupljeni na web stranicama su Broj telefaksa (25%) i Povijest hotela koju ima svega 10% hotela. Telefaks je oblik komunikacije koji se koristio u bliskoj prošlosti te ga je u novije vrijeme zamijenila uglavnom elektronička pošta pa je razumljivo zašto je ovako malena zastupljenost. Kad govorimo o Povijesti hotela, veliki dio hotela koje su bili objekt istraživanja su u stranom vlasništvu te nemaju neku dugu tradiciju poslovanja pa to nije ni istaknuto. Isto tako je i zanimljivo da većina hrvatskih hotelskih lanaca s dugom tradicijom poslovanja nemaju ovaj element na svojim stranicama pa ostaje pitanje je li to dio strategije poslovanja, odnosno oglašavanja ili se pak radi samo o previdu kod izrade web stranice.

Sljedeći elementi koji su istraživani se odnose na elemente interakcije sa stranicom.

- Mogućnost prijave (sign-up) – prijava na stranicu koja omogućava personalizirani pregled stranice
- Posebni dodaci na stranici – dodaci poput tablice deviznih tečajeva, pretvarača valuta, kalkulatora cijene smještaja i sl.
- Recenzija – ocjena i iskustva gostiju koji su odsjeli u hotelu
- Vijesti – novosti vezane uz hotelsku ponudu ili sam hotel
- Blog – stranice na kojima se mogu saznati različite informacije o hotelu, događajima, znamenitostima i sl.
- Link na društvene mreže – poveznica na profile poduzeća na društvenim mrežama



- Galerija slika ili videa – galerije sa vizualnim sadržajima hotelskog smještaja i ponude
- Newsletter – mogućnost prijave za dobivanje novosti o hotelskoj ponudi
- Pretraživač – filter ili tražilica na stranici putem koje posjetitelj može na stranici pronaći informacije koje ga zanimaju ili na brz način doći do cijena za odabrani tip smještaja i razdoblje
- Chat – oblik komunikacije s posjetiteljem u kojem može trenutno saznati informacije koje ga zanimaju

Tablica 4. Zastupljenost elemenata koji se odnose na interakciju posjetitelja sa stranicom

Elementi interakcije sa stranicom	Hoteli koji imaju navedene elemente (%)
Mogućnost prijave - sign up	55,00%
Posebni dodaci na stranici	25,00%
Recenzije	70,00%
Vijesti	40,00%
Blog	20,00%
Link na društvene mreže	95,00%
Galerija slika ili videa	95,00%
Newsletter	70,00%
Pretraživač	95,00%
Chat	5,00%

Izvor: Samostalno istraživanje

Elementi interakcije s web stranicom imaju vrlo važnu ulogu i mogu uvelike utjecati na odabir smještaja. Prema rezultatima istraživanja tri elementa su se pokazala kao gotovo

neizostavni na svim web stranicama. To su Link na društvene mreže, Galerija slika ili videa te Pretraživač, odnosno tražilica na stranici, a zastupljeni su na 95% pretraživanih stranica.

Integracija različitih oblika komunikacije s publikom je postala neizostavna strategija svih modernih marketinških planova hotelskih poduzeća pa je jasno zašto su poveznice na profile poduzeća na društvenim mrežama toliko zastupljeni. Galerija slika ili videa je jedan od neizostavnih dijelova izrade moderne web stranice hotela. Turisti svoj odabir smještaja u većini slučajeva temelje na osnovu vizualnih doživljaja hotela pa je važno prikazati na što bolji i atraktivniji način s što više vizualnih sadržaja. Pretraživač, filter ili tražilica na stranici je vrlo popularna jer posjetitelj u nekoliko koraka može doći do informacija koje su mu najbitnije. Npr. odabirom datuma i broja osoba može u trenutku doći do informacije o cijeni smještaja za odabrani period.

Ono što je turistima pri odabiru smještaja vrlo važno su iskustva drugih posjetitelja s hotelskim poduzećem, stoga dobar dio hotela (70%) na svojim stranicama ima sekciju Recenzije. Nažalost, tu se uglavnom radi o odabranim recenzijama od strane samog hotela i ponekad ne daju pravu sliku, ali pojedini hoteli pružaju linkove na eksterne izvore, kao što je Trip Advisor, koji su dosta relevantniji. Velika zastupljenost Newsletter elementa (70%) putem kojeg se posjetitelje može na mail adresu obavještavati o novostima u ponudi hotela je pokazatelj da je dobar dio hotela svjestan važnosti proaktivnog marketinškog djelovanja. Mogućnost prijave (sign-up) na stranicu se odnosi na personalizaciju pretrage stranice, a i često je vezana s programima vjernosti i u posljednje vrijeme se sve više koristi kod izrade stranica s modernim dizajnom i bogatom ponudom smještaja. Prema istraživanju vidimo da tek nešto više od polovice hotela (55%) ima ovu mogućnost što nije dobar pokazatelj. Obavijesti o novostima u ponudi hotela nudi posjetiteljima informacije koje ih mogu potaknuti na rezervaciju smještaja ili dati informaciju koja će ih u budućnosti potaknuti na rezervaciju, prema istraživanju tek 40% hotelskih poduzeća koristi ovaj način obavještavanja posjetitelja.

Kao najmanje zastupljeni elementi su se pokazali Dodatni elementi na stranici (25%), Blog (20%) i Chat (5%). Dodatni elementi kao npr. valutni tečaj, pretvarač valuta, kalkulator i sl. Mogu biti vrlo zgodni elementi koji će omogućiti posjetitelju korisničko iskustvo na stranici

te lakši način dobivanja informacija. Blog je zanimljiv izvor informacija za posjetitelje gdje mogu saznati sve o smještaju, ali i drugim informacijama kao što su aktivnosti ili mjesta koje mogu posjetiti dok su na odmoru. Chat omogućava posjetitelju brzo dobivanje odgovora na sva pitanja na koje nije mogao pronaći odgovore na stranici.

Ove elemente koriste uglavnom poduzeća koja imaju nešto razvijenije marketinške strategije i napore.

Elementi rezervacije smještaja su od ključne važnosti za hotelska poduzeća jer se u moderno doba većina rezervacija odvija putem web stranica.

- Istaknute cijene smještaja – cijene smještaja jasno vidljive i istaknute na web stranici
- Opći uvjeti poslovanja – opći uvjeti poslovanja u kojima su istaknute sve pravne obveze i prava poduzeća i posjetitelja
- Posebne ponude – izvanredne ponude koje se razlikuju od standardnih cijena i uvjeta
- Mogućnost rezervacije – postoji li bilo kakva mogućnost rezervacije smještaja putem web stranice?
- Računalni rezervacijski sustav (CRS) – sustav za rezervaciju smještaja
- Prihvat kartica – koje se sve kartice i prihvaćaju li se oblici plaćanja putem kartice?

Tablica 5. Zastupljenost elemenata rezervacije smještaja

Elementi rezervacije smještaja	Hoteli koji imaju navedene elemente (%)
Istaknute cijene smještaja	100,00%
Opći uvjeti poslovanja	100,00%
Posebne ponude	90,00%
Mogućnost rezervacije	100,00%
Računalni rezervacijski sustav (CRS)	100,00%
Prihvat kartica	100,00%

S obzirom na važnost za hotelska poduzeća, ne iznenađuje da skoro sva poduzeća imaju sve promatrane elemente na svojim stranicama. Tek Posebne ponude se ističu kao element koji nemaju baš svi hoteli. Računalni rezervacijski sustav (CRS) je postao neizostavan na svakoj modernoj web stranici te oni hoteli čije web stranice ga ne sadrže mogu kod posjetitelja stvoriti dojam zastarjelosti zbog zaostajanja za modernim trendovima što može negativno utjecati na poslovne rezultate. Također, većina posjetitelja je navikla na online rezervacije smještaja i manje je vjerojatno da će smještaj rezervirati putem drugih oblika komunikacije.

Kao način plaćanja, prihvrat različitih kartica je postao vrlo važan. Što je veći raspon kartica koje hotel prima, veće su i šanse rezervacije posjetitelja iz različitih zemalja.

- Vlastita domena – hotel ima vlastitu domenu koja nije dio šire ponude hotelskog lanca
- Domena poduzeća – hotelska domena je dio šire ponude hotelskog lanca
- Domena “.hr“ – domena je registrirana na hr
- Domena “.com“ – domena je registrirana na com
- Domena “.ostalo“ – domena je registrirana na neki drugi završetak

Sljedeći na redu su elementi domene.

Tablica 6. Zastupljenost elemenata domene

<b>Domena</b>	<b>Hoteli koji imaju navedene elemente (%)</b>
Vlastita domena	65,00%
Domena poduzeća	35,00%
.hr	15,00%
.com	85,00%
.ostalo	0,00%

Pregled elemenata domene nam daje nekoliko zanimljivih informacija. Kako možemo vidjeti veći dio hotela ima svoju osobnu domenu koja nije dio hotelskog lanca što ukazuje na važnost koncentracije na pojedini objekt. Zanimljivo je i da je većina hotela (85%) registrirana pod “.com“, a razlog je vrlo vjerojatno orijentiranost na goste s vanjskih tržišta. Tek 15% hotela ima domenu s “.hr“ dok nijedan hotel nema domenu koja završava nekim drugim nastavkom.

Od ostalih elemenata koji su bitni kod dizajna stranice su izdvojeni sljedeći:

- Program vjernosti – program vjernosti u kojem članovi stječu razne pogodnosti
- FAQ – odgovori na često postavljena pitanja
- Posebna događanja – turistička ili kulturna događanja u blizini hotela
- Stranice na više jezika – mogućnost pregleda stranice na više od jednog jezika

Tablica 7. Zastupljenost ostalih elemenata na stranici

Ostali elementi	Hoteli koji imaju navedene elemente (%)
Program vjernosti	60,00%
FAQ	40,00%
Posebna događanja	90,00%
Stranice na više jezika	90,00%

Izvor: Samostalno istraživanje

Od ostalih elemenata koji su važni kod izrade web stranice, popularno je da su stranice prevedene na više jezika (90%). Od istraživanih stranica sve stranice imaju opciju odabira engleskog jezika, dok 80% stranica ima mogućnost odabira hrvatskog jezika. Iza njih je najpopularniji njemački, talijanski i francuski jezik.

Većina stranica (90%) sadrži informacije o različitim događanjima koji se odvijaju u bližoj ili široj okolini hotela. Na ovaj način se pružaju posjetiteljima informacije o stvarima koje bi mogli raditi dok su hotelu, a nerijetko su upravo takvi događaji razlog rezervacije smještaja.

Program vjernosti su vrlo popularan element kod modernih hotelskih poduzeća. Ovim putem hoteli žele stvoriti lojalne klijente te im nude različite pogodnosti slučaju kontinuirane vjernosti pri rezervaciji smještaja.

FAQ ili Često postavljena pitanja je sekcija u kojoj su pruženi odgovori na pitanja koja uglavnom zanimaju posjetitelje, a koja nisu navedena nigdje drugo na stranici.

Također, provedeno je i istraživanje o implementiranosti Google Analyticsa na stranici. Rezultati istraživanja su pokazali da 95% web stranica ima instaliran Google Analytics kod što znači da se promet na stranicama prati i analizira.

## **5. Rezultati istraživanja i prijedlog izrade web stranice**

Na osnovu rezultata istraživanja kreiran je izvještaj u kojem je prikazana distribucija zastupljenosti elemenata na web stranicama koje su analizirane u izvještaju.


Izvještaj je napravljen u obliku grafikona zbog jednostavnijeg i preglednijeg izgleda. Elementi su poredani prema zastupljenosti, od najmanje zastupljenih na dnu prema onim najzastupljenijima na vrhu.

Iz izvještaja možemo zaključiti da većina hotelskih poduzeća ima moderno dizajnirane web stranice koje su u skladu s trendovima na svjetskim tržištima. Iako je određen dio hotela iz pretraživanja pod vlasništvom velikih svjetskih hotelskih lanaca, može se zaključiti da i domaći hoteli, odnosno hotelski lanci ne zaostaju za svjetskim standardima izrade web stranica.

Za elemente koji su zastupljeni na više od 80% stranica možemo zaključiti da su praktički standard kod izrade web stranica i većina hotelskih poduzeća koja ulažu u web stranice ih imaju. Među njima se posebno izdvajaju računalni rezervacijski sustav, prihvati kartica, galerija slika i videa, pretraživač, stranice na više jezika, mogućnost rezervacije i posebne ponude koje su posjetiteljima vrlo važni pri odabiru smještaja.

Elementi koji su zastupljeni na manje od 60% stranica možemo podijeliti u dvije kategorije. Jedna kategorija su oni elementi koje imaju samo hoteli koji ulažu veća sredstva i napore u dizajn i korisničko iskustvo stranice. Primjer takvih elemenata su chat, mogućnost prijave na stranicu i personalizirani pregled, posebni dodaci na stranici, blog i program vjernosti. Zanimljiv je podatak da od promatranih domaćih poduzeća, većina njih ima zastupljene ove elemente na svojim stranicama. Druga kategorija su elementi koji su već pomalo zastarjeli ili su posljednjih godina posjetiteljima postali manje važni, primjer takvih su telefaks i FAQ.

Graf 3. Zastupljenost elemenata na web stranicama hotela



Izvor: Ručno kreiran graf u MS Excel



Na osnovu izvještaja se predlažu elementi koje će nova web stranica hotelskog poduzeća Colosseum sadržavati.



Dakle, kod izrade novog weba poduzeća, određeno je pet kategorija elemenata koje će web stranica sadržavati. Web stranica hotela Colosseum će sadržavati informacije o adresi sjedišta hotela, kategoriji svih hotela koji se nalaze u sastavu poduzeća, broj telefona i mail adresu na kojoj posjetitelji mogu dobiti dodatne informacije. Google karta s označenom lokacijom hotela, opis dolaženja do hotela i udaljenost hotela od značajnijih lokacija i destinacija će pomoći gostima da lakše pronađu put do hotela ili vide smještaj hotela unutar destinacije i tako dobiju dojam njegove geografske lokacije i okružja. Vanjske poveznice će voditi na stranice koje posjetiteljima mogu dati neke korisne informacije poput web stranice Hrvatske turističke zajednice i web stranica partnera poduzeća.

Nova web stranica će imati mogućnost kreiranja računa kako bi posjetitelji mogli imati personalizirani pregled stranica te preko svog računa skupljati bodove vjernosti za svaku rezervaciju. Mogućnost recenzije će imati posjetitelji koji imaju kreiran račun na stranici pod uvjetom da su odsjeli u hotelu. Stranica će sadržavati sekciju s vijestima koje će se odnositi na hotele unutar lanca, a na stranicu će biti i integrirane poveznice koje će voditi na profile poduzeća na društvenim mrežama. Također, stranica će imati i mogućnost prijave na newsletter kako bi posjetitelji mogli dobivati novosti o ponudi hotela direktno na svoju mail adresu. Galerija slika i videa će sadržavati multimedijalne sadržaje koji će se odnositi na hotele, atmosferu u hotelima, uređenje hotela i događaje u hotelima. Pretraživač će biti integriran na stranicu kako bi posjetitelji mogli što lakše pronaći raspoložive kapacitete u vremenskom razdoblju koje ih zanima, a stranica će imati i chat kako bi posjetitelj mogao što brže saznati informacije koje mu trebaju te rezervirati smještaj na brz način. Prema istraživanju, chat je element kojeg ima tek jedan hotel, ali se poduzeće odlučilo na implementaciju chata kako bi omogućilo korisnicima što bolje korisničko iskustvo.

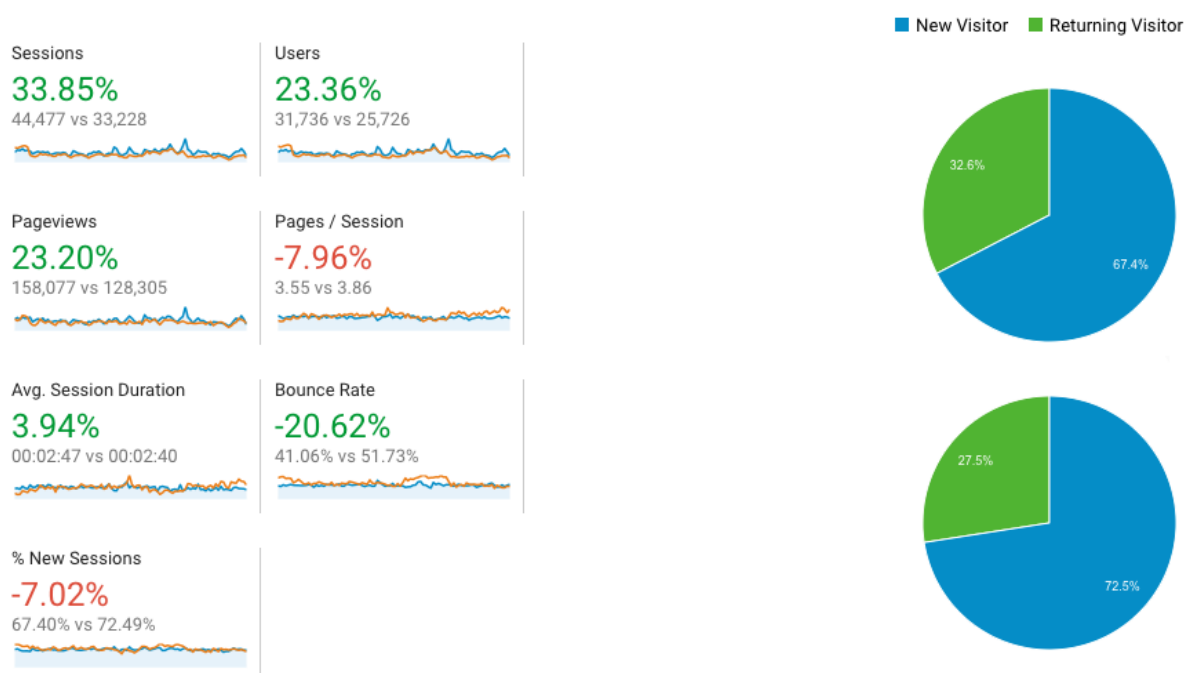
Na web stranicama korisnici će imati mogućnost rezervacije, moći će rezervirati smještaj pomoću chata i preko rezervacijskog sustava. Plaćanje preko sustava za rezervaciju će se provoditi preko kartica, a primat će se Visa, Maestro, Amex, Diners i Mastercard kartice. Web stranica će sadržavati opće uvjete poslovanja kako bi posjetitelji mogli saznati svoja prava i obveze. Cijene smještaja će biti vidljive i dostupne uz svaku kategoriju smještaja, a stranica će sadržavati i sekciju posebnih ponuda gdje će biti istaknuti aktualni popusti i akcije.

Web domena će se zadržati te će kao i dosad biti colosseum-hotels.com. Na stranici će biti istaknuta posebna događanja koja se odvijaju u hotelima ili u destinacijama u kojima su hoteli smješteni kao i “što raditi“ prijedlozi. Poduzeće je odlučilo uvesti i program vjernosti koji će biti dostupan nakon kreiranja računa na stranici. Stranice će se dizajnirati na engleskom, hrvatskom, njemačkom, talijanskom, francuskom, slovenskom, češkom i ruskom jeziku, a da bi se mogao pratiti promet na stranicama će biti instaliran Google Analytics.

## 5.1.Rezultati nakon implementacije

Nakon implementacije predloženih elemenata i izrade nove web stranice, praćeni su rezultati u sljedećem tromjesečju te su uspoređeni s istim razdobljem u prethodnoj godini kad je korištena stara web stranica.

Slika 10. Usporedba razdoblje prije i nakon nove web stranice



Izvor: analytics.google.com

Kako je vidljivo na slici iznad, u razdoblju nakon implementacije nove web stranice došlo je do povećanja broja sesija za 33,85% u odnosu na isto razdoblje u prethodnoj godini. Također,

broj korisnika koji su došli na web stranice je isto porastao za 23,36%. Broj pregleda stranice (Pageview) je porastao za 23,20%, a stopa napuštanja se smanjila za 20,62% što je izvrstan rezultat. Ovakvi rezultati ukazuju da je nova web stranica ispunila očekivanja te se povećao promet na stranici, a niža stopa napuštanja ukazuje na to da je stranica zanimljivija korisnicima. Ipak, posljedica ovakvih rezultata može biti i povećana marketinška aktivnost na internetu. Stoga, važno je vidjeti kakav je promet na stranici bio prema izvorima prometa.

Slika 11. Promet na web stranici prema izvorima prometa

1. google / organic	2. (direct) / (none)	3. google / cpc	4. m.facebook.com / referral
Sessions	Sessions	Sessions	Sessions
18,043	0	0	0
9,757	0	0	0
84.92%	0.00%	0.00%	0.00%
0	9,810	0	0
0	6,243	0	0
0.00%	57.14%	0.00%	0.00%
0	0	8,254	0
0	0	9,275	0
0.00%	0.00%	-11.01%	0.00%
0	0	0	1,045
0	0	0	0

Izvor: analytics.google.com

Analiza statistike prema izvorima prometa jasno pokazuje da je najviše porastao organski promet, čak za 84,92 % što je jasan pokazatelj da nova stranica s poboljšanjima SEO elemenata pokazuje veliki pomak kad je riječ o povećanju prometa na stranici.

Optimizacija brzine stranica, moderan dizajn i elementi koji su u skladu s modernim svjetskim standardima izrade web stranice su utjecali na povećanje prometa, a osim organskog prometa, došlo je i do rasta direktnog prometa za 57,14%. S obzirom da poduzeće nije poduzimalo veće marketinške napore u promatranom razdoblju, iz tablice možemo vidjeti da je zapravo promet s AdWords kampanja opao za 11,01%.

Dakle, možemo zaključiti da je rast prometa na web stranici direktna posljedica implementacije nove web stranice koja sadrži elemente koji su predloženi modelom dobivenim na osnovu rudarenja podataka web stranica konkurentskih poduzeća.

## **5.2. Testiranje i potvrda hipoteza**

Nakon dobivenih rezultata istraživanja, pristupilo se testiranju i potvrđama hipoteza.

**Glavna hipoteza  $H_0$ :** Analitika web stranica hotela utječe na povećanje prometa na web stranicama hotela Colosseum.

Usporedbom rezultata iz prvog tromjesečja nakon implementacije stranice s istim razdobljem u prethodnoj godini kad se koristila stara web stranica, utvrđeno je povećanje broja sesija za 33,85% te rasta ukupnog broja korisnika za 23,36%. Uočeno je i smanjenje stope napuštanja za 20,62%, a svi ovi pokazatelji su očiti dokaz da je nova web stranica privukla veći broj kvalitetnih posjetitelja. Također, utvrđeno je da su svi novi posjetitelji na stranicu došli putem organskog ili direktnog prometa što je još jedan dokaz uspješnosti projekta nove web stranice. Ovi rezultati sugeriraju da je Glavna hipoteza istinita.

**Hipoteza 2  $H_0$ :** Web analitikom se mogu utvrditi problemi na web stranici

Analizom statistika prometa na Google Analyticsu je utvrđeno da se velika većina sesija (243,131) na staroj web stranici odnosila samo na jednu sesiju, a najveći dio prometa je došao putem direktnog prometa koji je bi za cca 8% veći od organskog izvora prometa. Ova dva

problema ukazuju da je bio moguć problem s organskom pozicijom web stranice te da je sadržaj stranice bio nezanimljiv i neatraktivan pa su korisnici uglavnom napuštali web stranicu nakon jedne sesije. Dakle, stranica je imala nisku ocjenu od strane Googlea radi različitih tehničkih značajki te je bila i loše rangirana. Analizom je utvrđeno i da je najviše prometa ostvareno s područja Republike Hrvatske što nije dobar pokazatelj s obzirom da su oni vrlo malo zastupljeni u strukturi gostiju hotela. Svi ovi problemi su utvrđeni isključivo analizom prometa na web stranicama putem Google Analyticsa, stoga se može zaključiti da je postavljena hipoteza istinita.

**Hipoteza 3 H<sub>0</sub>:** Google Analytics je najčešće korišten alat za analitiku prometa s web stranica hotela u Hrvatskoj.

Provedeno je istraživanje na web stranicama hotelskih poduzeća koja su bila dio istraživanja te je pomoću Google Tag Manager Asistent ekstenzije utvrđeno da 95% pregledanih web stranica ima instaliran Google Analytics kao alat za praćenje prometa s web stranica što potvrđuje istinitost hipoteze.

## 6. Zaključak

Moderni dizajn web stranice koji će privući posjetitelje na tzv. “engagement“ ili uključenost sa stranicom, dakle web stranice na koje će posjetitelji doći te ispuniti očekivane radnje su postale centralni problem poduzeća koja se bave pružanjem usluga hotelskog smještaja. S obzirom da je rezervacija hotelskog smještaja putem web stranica postala pravilo, a ne trend, sva hotelska poduzeća moraju prilagoditi svoje web stranice kako bi imale što bolje korisničko iskustvo te kako bi posjetitelj mogao dobiti što više informacija te rezervirati smještaj. Cilj ovog rada je bio izraditi model web stranice koja će sadržavati sve prethodno navedene značajke te ostvariti povećanje prometa što bi u konačnici moglo rezultirati i povećanjem broja rezervacija preko web stranice.

U prvom dijelu rada je dan osvrt na korištenje alata poslovne inteligencije u hotelima na području Republike Hrvatske. Poslovna inteligencija je još relativno stran pojam za većinu

hotela i vrlo malen broj hotela uopće koristi bilo kakve alate poslovne inteligencije pomoću kojih bi mogao unaprijediti svoje poslovanje.

Drugi dio rada je usmjeren na teorijska razmatranja o elementima web stranica hotelskih poduzeća. Utvrđeni su osnovni elementi koje bi web stranica trebala sadržavati kako bi posjetitelju pružila relevantne i interesantne informacije. Osim elemenata web stranica, razmotrena je i web analitika prometa sa stranica, koje su koristi i prednosti web analitike, kakve informacije poduzeće može dobiti od nje te koji su najpopularniji alati za web analitiku.

Empirijski dio rada je usmjeren na rješavanje problema pri izradi nove web stranice hotelskog poduzeća Colosseum d.d.. Kako su u poduzeću Colosseum d.d., na osnovu analize rezultata iz Google Analyticsa, shvatili da imaju zastarjelu web stranicu na kojoj nedostaje niz elemenata kako bi bila atraktivnija, pružala veću mogućnost interakcije i veći broj informacija relevantnih potencijalno gostu hotela, odlučili su se na izradu nove web stranice koja će ispunjavati sve uvjete modernog web dizajna. Kako bi dobili jasnu sliku, odnosno viziju koje bi sve elemente nova web stranica trebala sadržavati, odlučili su se na prikupljanje podataka s web stranica konkurentskih poduzeća unutar Republike Hrvatske. Odabrano je dvadeset velikih hotelskih poduzeća koja su kategorizirana s tri ili četiri zvjezdice. Rudarenjem podataka su se pretraživali elementi koje posjeduje većina web stranica konkurentskih poduzeća. Utvrđeno je pet osnovnih kategorija, koje su sadržavale niz različitih elemenata koje će nova web stranica sadržavati. Kategorije su podijeljene na Informacije o poduzeću, Interakcija s web stranicom, Rezervacija smještaja, Domena i Ostali elementi. Tim koji je bio zadužen za razvoj stranice je dobio zadatak da na novu stranicu implementira ukupno 23 elementa. Razvojni tim je dobio slobodne ruke u vidu izbora programskog jezika u kojem će web biti kreiran, različitih tehničkih i SEO elemenata kao i vizualni dizajn stranice.

Posljednji dio rada je usmjeren na interpretaciju izvještaja istraživanja i utvrđivanje istinitosti hipoteza. Nakon implementacije stranice, usporedba rezultata prvog tromjesečja s istim razdobljem iz prošle godine je pokazala da je došlo do povećanja prometa na web stranici te smanjenja stope napuštanja. Dakle, nova web stranica koja je izrađena prema odrednicama koje su donesena na osnovu rudarenja podataka s web stranica konkurentskih poduzeća se pokazala uspješnom te je uz to potvrđena glavna hipoteza i pomoćne hipoteze kao istinite. Svi

postavljeni ciljevi rada su u konačnici i ispunjeni te je rad dokazao koliku važnost ima web analitika pri izgradnji, praćenju i utvrđivanju uspješnosti rezultata web stranica hotelskih poduzeća.



## LITERATURA

Bekavac I., Praničević D. G. (2015): Web analytics tools and web metrics tools: An overview and comparative analysis, Croatian Operational Research Review, Split. Preuzeto: [06.05.2017.]

Bilandžić M. (2008.): Poslovnoobavještajno djelovanje: business intelligence u praksi, AGM, Zagreb.

Bilandžić, M., Čulig B., Lucić D., Putar-Novoselac, M., Jakšić, J. (2012.): Business Intelligence u hrvatskom gospodarstvu, Poslovna Izvrnost Zagreb, Br. 1, Zagreb. Preuzeto: [18.01.2017.]

Creative Commons Organization (2012.): Online Marketing Essentials, Creative Commons, New York. E-book. Preuzeto: [25.02.2017.]

Cutroni, J. (2010.): Google Analytics, O'Riley Media, Sebastopol.

Geo Trust Inc. (2011.): Introduction to web analytics for e-commerce: How to track activity to optimize your web site, e-vodič, Geo Trust, Mountain View. E-book. Preuzeto: [04.02.2017.]

Global Intelligence Alliance (2005.): Developing an Intelligence System, GIA White Paper 1/2005. Preuzeto: [14.02.2017.]

Javorović B., Bilandžić M. (2007.): Poslovne informacije i Business Intelligence, Golden marketing, Zagreb.

Kaushik, A. (2010.): Web Analytics 2.0, Wiley Publishing, Inc., Indianapolis, Indiana

Kozak, M. i Decrop, A. (2009.): Handbook of Tourist Behavior: theory & practice, Taylor & Francis, New York, New York.

Kraljić, I., Lončarić, D. (2015.): Ispitivanje važnosti sadržaja web stranica hotela iz perspektive ciljnog tržišta, Visoka poslovna škola PAR, Rijeka.

Marković S., Raspor S., Car T., Komšić J. (2012.): Content analysis of hotel websites: case study of Croatia, *Negotia*, br. 57, str. 27-37 Preuzeto: [01.03.2017.]

Moutinho, L. (2000.): *Strategic Management in Tourism*, CABI Publishing, Wallingford.

Panian Ž., suradnici, (2007.): *Poslovna inteligencija – studije slučajeva iz hrvatske prakse*, Narodne novine, Zagreb.

Peterson T. E. (2004.): *Web analytics demystified*, Celilo Group Media, E-book Preuzeto: [17.01.2017.]

Tambourine Marketing agency blog (2005.): *The Surprising Psychology Behind Successful Hotel Websites: Part One*. Preuzeto: [14.04.2017.]

Tutorials Point (2015.): *Web analytics*, E-book. Preuzeto: [05.03.2017]

Texeira, J. (2011.): *Get Involved: 5 types of web analytics tools to start using today!*, E-book. Preuzeto: [06.05.2017.]

Weiss A. (2005.): *Justifying CI Activities*, *Competitive Intelligence Magazine*, Vol. 8, Br. 6.

[www.statista.com](http://www.statista.com) Preuzeto: [26.08.2016.]

[http://www.unizd.hr/portals/4/nastavni\\_mat/1\\_godina/metodologija/metode\\_znanstvenih\\_istra\\_zivanja.pdf](http://www.unizd.hr/portals/4/nastavni_mat/1_godina/metodologija/metode_znanstvenih_istra_zivanja.pdf) Preuzeto: [10.09.2016.]

Google Analytics račun anonimnog izvora nazvanog Colosseum d.d.

## **TABLICA GRAFOVA**

Graf 1. Zastupljenost BI u hrvatskim poduzećima .....	13
Graf 2. Zastupljenost BI prema djelatnosti.....	14
Graf 3. Zastupljenost elemenata na web stranicama hotela.....	64

## **TABLICA SLIKA**

Slika 1. Proces web analitike.....	25
Slika 2. Funnel analiza .....	27
Slika 3. Segmentacija prometa po spolu.....	38
Slika 4. Izbornik s izvještajima u Google Analyticsu.....	39
Slika 5. Distribucija posjetitelja poduzeća Colosseum hoteli d.d. ....	47
Slika 6. Frekvencija i učestalost posjeta.....	48
Slika 7. Distribucija prometa prema izvorima.....	49
Slika 8. Distribucija posjetitelja prema lokaciji.....	50
Slika 9. Distribucija podataka prema vrsti uređaja.....	51
Slika 10. Usporedba razdoblje prije i nakon nove web stranice .....	67
Slika 11. Promet na web stranici prema izvorima prometa .....	68

## **TABLICA TABLICA**

Tablica 1. Alati za web analitiku.....	35
Tablica 2. Hoteli na kojima je provedeno istraživanje .....	53
Tablica 3. Zastupljenost elemenata koji daju informacije o hotelu na web stranici .....	54

Tablica 4. Zastupljenost elemenata koji se odnose na interakciju posjetitelja sa stranicom.....	57
Tablica 5. Zastupljenost elemenata rezervacije smještaja .....	59
Tablica 6. Zastupljenost elemenata domene.....	60
Tablica 7. Zastupljenost ostalih elemenata na stranici .....	61